

Brenda Jennifer Sousa Nogueira

Identificação de Acidente Vascular Cerebral Isquêmico por Imagens de Tomografia Computadorizada

João Pessoa – PB
Dezembro de 2024



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA

PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU*

MESTRADO EM ENGENHARIA ELÉTRICA

BRENDA JENNIFER SOUSA NOGUEIRA

**IDENTIFICAÇÃO DE ACIDENTE VASCULAR CEREBRAL ISQUÊMICO POR IMAGENS DE
TOMOGRAFIA COMPUTADORIZADA**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica pelo Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – IFPB - Campus João Pessoa.

Aprovado em 09 de dezembro de 2024.

Membros da Banca Examinadora:

Dr. Carlos Danilo Miranda Regis

IFPB – PPGEE

Dra. Suzete Élide Nóbrega Correia

IFPB - PPGEE

Dra. Silvana Luciene do Nascimento Cunha Costa

IFPB - PPGEE

Documento assinado eletronicamente por:

- **Carlos Danilo Miranda Regis**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/12/2024 11:54:25.
- **Silvana Luciene do Nascimento Cunha Costa**, PRO-REITOR(A) - CD2 - PRPIPG-RE, em 11/12/2024 14:33:13.
- **Suzete Elida Nobrega Correia**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 16/12/2024 11:23:30.

Este documento foi emitido pelo SUAP em 11/12/2024. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 644768
Verificador: d1df277df2
Código de Autenticação:



Av. Primeiro de Maio, 720, Jaguaribe, JOAO PESSOA / PB, CEP 58015-435
<http://ifpb.edu.br> - (83) 3612-1200

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Nilo Peçanha do IFPB, *campus* João Pessoa

N778i Nogueira, Brenda Jennifer Sousa.

Identificação de acidente vascular cerebral isquêmico por
imagens de tomografia computadorizada / Brenda Jennifer
Sousa Nogueira. – 2024.

71 f. : il.

Dissertação (Mestrado – Engenharia Elétrica) – Instituto
Federal de Educação da Paraíba / Programa de Pós-Graduação
em Engenharia Elétrica (PPGEE), 2024.

Orientação : Prof^o Dr Carlos Danilo Miranda Regis.

1. Tomografia computadorizada. 2. Acidente vascular
cerebral isquêmico. 3. Redes neurais artificiais. 4. Descritores
Haralick. 5. CNN. I. Título.

CDU 616-073.7(043)

Bibliotecária responsável: Lucrecia Camilo de Lima – CRB 15/132

DEDICATÓRIA

Dedico este trabalho primeiramente a Deus, afinal foi Ele que sempre cuidou de mim, me acompanhou nesta jornada e me amparou todos os dias. Também gostaria de dedicar este projeto ao meu companheiro, André Nascimento, que com sua paciência e amor me deu muito apoio. Aos meus amigos de laboratório, Emanuel e Villeneve, que passaram longas tardes dividindo conhecimento e boas conversas. Ao meu orientador, doutor Carlos Danilo, que acreditou em mim, sempre teve muita fé neste projeto. À minha família que mesmo de longe, me acompanha e se alegra comigo. Dedico a todos vocês com muito amor e carinho este trabalho.

AGRADECIMENTOS

Em uma jornada tão extensa, e de muitos desafios, é impossível chegar ao êxito sozinha, precisamos de amigos, e eu tive os mais engraçados, inteligentes e singulares, Villeneve, Emanuel, Pedro, Kamily, Waléska, João Neto, Gabriel, Felipe, Emily, Asis, Sara e Walliomar, todos contribuíram de alguma forma para que este momento fosse real, para que eu pudesse chegar até aqui. Ainda sim, somente com amigos em certas jornadas não é o suficiente, e eu fui agraciada com uma família cheia de defeitos, mas, nenhum marinheiro torna-se bom em mar calmo, não é mesmo? Então, Wanda, Wando, Nanal, Miakely, Carol e Marynilce, vocês também têm a minha gratidão, pelas orações e pelo tempo disposto, pela ajuda financeira e apoio moral. Mesmo com amigos e família, todo mundo quer um amor, e o meu, André Nascimento, é o homem mais paciente do mundo, podem acreditar, sem você eu teria desistido no primeiro dia. Professor, doutor Carlos Danilo, obrigada por cada palavra ensinada e eu não estou falando da engenharia, o senhor é um exemplo. Professoras, Silvana e Suzete, mulheres fascinantes, com histórias incríveis, vocês inspiram. Não poderia deixar de citar o médico que se tornou amigo e topou participar deste projeto, doutor André Moreira, que mesmo na correria colocou a mão na massa e analisou cada paciente como se fosse seu. Preciso também agradecer a CAPES, pelo suporte financeiro para o desenvolvimento desta dissertação. Aos meus alunos, que motivam e me inspiram a ser uma professora cada vez melhor, amo vocês. Eu não poderia esquecer Daquele que me protege desde do ventre, que acompanhou em cada lágrima, o único que me faz ter vontade de continuar, JESUS, o que seria de mim sem você aqui, devo tudo a você, é por você que acordo todos os dias, é por você que quero ser melhor, é por você que respiro. A todos vocês, o meu mais sincero obrigada! Deus abençoe abundantemente a vida de cada um.

Se eu desitir, qual a chance de dar certo?

Brenda Nogueira

RESUMO

O Acidente Vascular Cerebral, (AVC) é uma das doenças que causa mais mortes e incapacidades físicas no mundo. Por ser uma doença neurológica cada vez mais comum, por esse motivo cada vez mais pesquisadores se dispõem a encontrar um meio de acelerar o diagnóstico para evitar maiores sequelas. O método mais comum para a identificação do AVC, é o exame de Tomografia Computadorizada (TC), pois possui baixo custo e disponibilidade no mercado. O presente estudo desenvolve uma metodologia para análise e classificação de AVC isquêmico (AVCi), utilizando técnicas de aprendizado profundo de máquina (*Deep Learning*), que são redes são projetadas para aprender representações hierárquicas e complexas de dados, permitindo a identificação de padrões e características a partir de entradas como imagens, textos, sons ou sinais. O diferencial do aprendizado profundo está na capacidade de extrair automaticamente características relevantes dos dados, eliminando, em grande parte, a necessidade de intervenção humana no pré-processamento (ROSA; CLAUS; PAULA, 2024). Redes profundas, como as *Convolutional neural network* (CNNs), têm mostrado resultados impressionantes em tarefas como reconhecimento de fala, visão computacional, tradução automática e diagnósticos médicos. Esses modelos aprendem por meio de grandes volumes de dados e otimização baseada em retropropagação de erros (*backpropagation*), e técnicas como normalização, regularização e uso de grandes bases de dados anotadas. Embora poderoso devido a sua arquitetura projetada para processar dados estruturados em grades, como imagens, vídeos e sinais. O aprendizado profundo enfrenta desafios como alto custo computacional, necessidade de grandes volumes de dados e dificuldade de interpretabilidade, exigindo abordagens cuidadosas para garantir sua eficácia e aplicação ética. Neste trabalho destacam-se as redes neurais *MLP* (*Multi-Layer Perceptron*) e *Xception*, que são redes consolidadas. A primeira abordagem baseada em descritores de Haralick associados à rede MLP, os melhores resultados foram obtidos com a inclusão de metadados, como sexo e idade, e utilizando uma matriz de cocorrência com distância de 8 pixels. Essa configuração alcançou uma acurácia de 73,42% ,sensibilidade de 74,86%, Precisão de 72,83%, demonstrando a relevância da integração de informações clínicas. Por outro lado, Com a segunda abordagem com *Xception* apresentou desempenho superior, atingindo uma acurácia de 80,40%, precisão de 85,11% e sensibilidade de 74,10%, Foi observado algumas dificuldades persistiram na identificação das fases iniciais do AVCi, particularmente em pacientes idosos e do sexo feminino, devido a características fisiológicas, como maior presença de massa cinzenta.

Palavras-chave: Tomografia Computadorizada, Redes Neurais Artificiais, Descritores Haralick, CNN, Acidente Vascular Cerebral isquêmico, *Xception*.

ABSTRACT

Stroke is one of the diseases that causes the most deaths and physical disabilities in the world. As it is an increasingly common neurological disease, more and more researchers are willing to find a way to speed up diagnosis to avoid further consequences. The most common method for identifying stroke is the Computed Tomography (CT) exam, as it is low cost and available on the market. This study develops a methodology for analyzing and classifying ischemic stroke (CVA), using deep machine learning techniques (Deep Learning), which are networks designed to learn hierarchical and complex representations of data, allowing the identification of patterns and characteristics from inputs such as images, texts, sounds or signals. The difference with deep learning is its ability to automatically extract relevant characteristics from data, largely eliminating the need for human intervention in pre-processing (ROSA; CLAUS; PAULA, 2024). Deep networks, such as Convolutional neural networks (CNNs), have shown impressive results in tasks such as speech recognition, computer vision, machine translation and medical diagnostics. These models learn through large volumes of data and optimization based on backpropagation of errors, and techniques such as normalization, regularization and the use of large annotated databases. Although powerful due to its architecture designed to process structured data in grids, such as images, videos and signals, deep learning faces challenges such as high computational cost, the need for large volumes of data and difficulty in interpretability, requiring careful approaches to ensure its effectiveness and ethical application. In this work, the MLP (Multi-Layer Perceptron) and Xception neural networks, which are consolidated networks, stand out. The first approach based on Haralick descriptors associated with the MLP network, the best results were obtained with the inclusion of metadata, such as sex and age, and using a co-occurrence matrix with a distance of 8 pixels. This configuration achieved an accuracy of 73.42%, sensitivity of 74.86%, and precision of 72.83%, demonstrating the relevance of integrating clinical information. On the other hand, the second approach with Xception presented superior performance, reaching an accuracy of 80.40%, precision of 85.11%, and sensitivity of 74.10%. It was observed that some difficulties persisted in identifying the initial phases of ischemic stroke, particularly in elderly and female patients, due to physiological characteristics, such as greater presence of gray matter.

Keywords: Computed Tomography, Artificial Neural Networks, Haralick Descriptors, CNN, Ischemic Stroke.

LISTA DE ILUSTRAÇÕES

Figura 1 – Cérebro, veias e artérias.	24
Figura 2 – Forma estrutural básica de um neurônio.	25
Figura 3 – Lobos cerebrais.	26
Figura 4 – Divisão anatômica radiológica.	29
Figura 5 – Divisão anatômica radiológica por TC.	30
Figura 6 – Os dois tipos de AVC.	31
Figura 7 – Os quatro níveis de isquemia de um AVC.	32
Figura 8 – Escala Hounsfield.	36
Figura 9 – Representação imagem DICOM.	37
Figura 10 – Representação de uma arquitetura CNN.	39
Figura 11 – Representação de uma arquitetura MLP.	44
Figura 12 – Fluxograma da metodologia.	48
Figura 13 – Exclusão de elementos externos.	49
Figura 14 – Matriz de Confusão dos resultados da rede <i>Xcepiton</i>	57
Figura 15 – Gráfico de resultados da rede <i>Xcepiton</i>	58

LISTA DE TABELAS

Tabela 1 – Estado da arte.	19
Tabela 2 – MLP e <i>Haralick</i> com metadados.	55
Tabela 3 – MLP e <i>Haralick</i> sem metadados.	56
Tabela 4 – Métricas de Avaliação do Modelo.	56

LISTA DE SIGLAS

ABTD	<i>Analysis of Brain Tissue Densities</i>
ACR-NEMA	<i>American College of Radiology - National Electrical Manufacturers Association</i>
AVC	Acidente Vascular Cerebral
AVCh	Acidente Vascular Cerebral hemorrágico
AVCi	Acidente Vascular Cerebral isquêmico
CNN	<i>Convolutional Neural Networks</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DenseNet	<i>Densely Connected Convolutional Networks</i>
FN	False Negatives
FP	False Positives
HU	<i>Hounsfield Unit</i>
IA	Inteligência Artificial
ML	<i>Machine Learning</i>
MLP	<i>Multi Layer Perceptron</i>
NEPI	Núcleo de Estudos e Pesquisa em Imaginologia
OMS	Organização Mundial de Saúde
Prec	Precisão
ResNet	<i>Residual Networks</i>
RN	Rede Neural
Sen	Sensibilidade
TC	Tomografia Computadorizada
TP	<i>True Positives</i>
3D	Tridimensional
UFPB	Universidade Federal da Paraíba

LISTA DE SÍMBOLOS

Γ	Letra grega Gama
kg	Quilograma
\in	Pertence
Λ	Lambda
s	Segundo
ζ	Letra grega minúscula zeta

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Motivação	16
1.2	Objetivos	17
1.2.1	Objetivos específicos	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Estado da Arte	19
2.2	O cérebro	23
2.2.1	Lobos cerebrais	26
2.3	Divisão anatômica radiológica	28
2.4	Acidente Vascular Cerebral	30
2.4.1	Níveis de isquemia	32
2.5	Tomografia Computadorizada	33
2.5.1	Escala Hounsfield	35
2.5.2	Imagem DICOM	36
3	INTELIGÊNCIA ARTIFICIAL	38
3.1	Redes Neurais Convolucionais	38
3.1.1	Filtros	40
3.2	Descritores <i>Haralick</i> e Rede Neural <i>Perceptron</i> Multicamadas	42
3.2.1	<i>Perceptron</i> Multicamadas MLP	43
3.2.2	Descritores <i>Haralick</i>	44
3.3	Rede CNN <i>Xception</i>	47
4	METODOLOGIA	48
4.1	Base de Dados	48
4.2	Pré-Processamento	49
4.3	Procedimento com Descritores <i>Haralick</i> e rede MLP	51
4.4	Procedimento com a Rede CNN <i>Xception</i>	52
5	ANÁLISE DE RESULTADOS	54
5.1	Análise com Descritores <i>Haralick</i> e rede MLP	55
5.2	Análise de resultados com a rede <i>Xception</i>	56
5.3	Comparação entre os resultados	60
6	CONCLUSÃO	61
7	TRABALHOS PUBLICADOS	63

REFERÊNCIAS	64
------------------------------	-----------

1. INTRODUÇÃO

O Acidente Vascular Cerebral (AVC) é uma condição que afeta a vascularização do cérebro, podendo causar sequelas neurológicas para o paciente, como a surdez, paralisia, demência, e até a morte. Os AVCs podem ser definidos pela peculiaridade da lesão cerebral, podendo ser resultante de infarto, denominado Acidente Vascular Cerebral Isquêmico (AVCi), ou decorrente de uma hemorragia, Acidente Vascular Cerebral Hemorrágico (AVCh) (SILVA; MIRANDA; MASAUD, 2015).

O AVC se apresenta como a segunda maior causa de mortalidade do mundo, nos últimos anos. Segundo a OMS, Organização Mundial de Saúde, anualmente 15 milhões de pessoas sofrem um AVC, dessas, 5 milhões têm posterior quadro de incapacidade. A projeção futura de tal cenário também traz indícios preocupantes, uma recente pesquisa publicada pela revista científica *Lancet Neurology*, prevê cerca de 10 milhões de mortes por AVC a cada ano no mundo até 2050 (YARIA et al., 2024).

No Brasil o cenário se repete, dados apontam o AVC como a causa mais frequente de morte para a população adulta. São 3,1 milhões de referências a diagnósticos de AVC, segundo a Pesquisa Nacional de Saúde de 2019 (BRASIL, 2019).

A incidência dos anos anteriores foram de 98.843 mortes em 2020, 103.054 em 2021 e 107.322 em 2022 (BRASIL, 2023). Adotar protocolos médicos eficientes e disponibilizar ferramentas que deem suporte a prevenção e ao rápido diagnóstico são mecanismos que podem colaborar significativamente com o controle e redução dos índices de morte por AVC no mundo.

A evolução no diagnóstico por imagem, possibilita identificar patologias de maneira ágil e em estágio precoce, auxiliando o tratamento e reduzindo possíveis riscos de morte. Dessa maneira, é coerente destacar que o progresso da tecnologia também se apresenta como potencial agente colaborador na prevenção, diagnóstico e tratamento de AVCs. Algumas aplicações tecnológicas podem ser apresentadas como ferramentas indicadas ao diagnóstico de AVC, a exemplo da tomografia computadorizada e ressonância magnética, sendo a tomografia computadorizada a mais usual, devido ao curto tempo de aquisição de dados e ao baixo custo, quando comparada a ressonância magnética (CONCEIÇÃO, 2023).

O avanço computacional também vem contribuindo consideravelmente para a melhoria do processamento e caracterização das imagens geradas pelos equipamentos de ressonância magnética e tomografia computadorizada. O aperfeiçoamento constante da tecnologia de *hardware* e *software*, a criação de sistemas dedicados, aliados a concepção de novos conceitos como Inteligência Artificial (IA) e Redes Neurais (RN) tem alavancado o surgimento de novas pesquisas relacionadas ao diagnóstico

de AVC (DINIZ et al., 2021).

Como mencionado, a evolução da medicina pode ser diretamente relacionada aos avanços da engenharia médica. As aplicações médicas também têm impulsionado pesquisas relacionadas a IA. As pesquisas sobre tal tema podem ser identificadas desde a década de 1950, porém só são potencializadas a partir da década de 1990, justificadas principalmente pela melhor validação prática dos conceitos das redes neurais, devido ao avanço tecnológico de *hardware* (CASTELO-BRANCO, 2018).

O aprendizado de máquina, ou *Machine Learning* (ML), é um ramo da IA que explora o estudo e a construção de algoritmos computacionais a partir do aprendizado por dados. Essas ferramentas estão presentes nas mais diversas áreas, para aplicações relacionadas ao tratamento e processamento de imagens. Pode-se perceber considerável evolução na parametrização e classificação de padrões de imagens, colocando-as como potenciais aliadas a equipe multidisciplinar para tratamentos e diagnósticos (PAIXÃO, 2022).

Um método bastante usual em desenvolvimento de IA's são as técnicas computacionais que utilizam modelos matemáticos inspirados na estrutura neural de organismo biológico, denominadas redes neurais artificiais. Uma rede neural artificial pode ser definida por um conjunto de unidades de processamento conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede. Existem vários modelos de rede neurais, podendo-se destacar as profundas, que são redes neurais com múltiplas camadas ocultas entre a camada de entrada e a de saída (TAULLI, 2020).

A profundidade da rede permite que ela aprenda representações hierárquicas e abstrações complexas dos dados, o que é útil para tarefas como reconhecimento de imagem, fala e processamento de linguagem natural. As convolucionais que são um tipo específico, que utiliza operações de convolução para capturar padrões locais dos dados elas são especialmente eficazes para análise de dados estruturados em grades, como imagens, em que convoluções detectam características como bordas, texturas e formas em diferentes escalas (SOUZA, 2023b). Temos como destaque também as recorrentes que podem ser projetadas para processar sequências de dados, como séries temporais ou textos. Elas mantêm uma memória interna ao permitir que as saídas de passos anteriores sejam usadas como entradas para os próximos passos. Isso as torna adequadas para tarefas em que a ordem e a dependência temporal são importantes (PAIXÃO, 2022).

Dito isso, pode-se observar que as ferramentas de suporte para o diagnóstico de

AVCi, estão em ascensão, porém, as patologias não fazem discriminação de pessoas e tem afetado cada vez mais todos da população, independentemente de sexo, cor e idade. Portanto, é imprescindível que pesquisas sejam feitas para construção de ferramentas para combater esse mal (NASCIMENTO et al., 2023).

A partir desse contexto, e da constante necessidade de melhoria quanto à assertividade e a eficiência na tomada de decisões em processos diagnósticos de AVC, tanto isquêmico como hemorrágico, pretende-se com este trabalho, propor uma metodologia de classificação de imagens por tomografia computadorizada, propor uma classificação utilizando redes neurais artificiais para AVCi.

1.1 MOTIVAÇÃO

A elaboração de algoritmos para a avaliação da área de isquemia em pacientes com AVC isquêmico (AVCi) é de extrema relevância clínica, uma vez que pacientes com grandes áreas de isquemia apresentam um risco significativamente elevado de complicações fatais, como hemorragias, após a administração da terapia trombolítica. Essa terapia, que é eficaz apenas quando administrada dentro de um prazo de até 4 horas após o início do quadro, pode ser prejudicial em casos de grandes áreas de isquemia. Portanto, a quantificação precisa da extensão das lesões isquêmicas, por meio da Tomografia Computadorizada (TC), é crucial para a seleção adequada dos pacientes que devem ser submetidos à administração do trombolítico, a fim de minimizar riscos e otimizar os resultados clínicos (SANTOS, 2020).

Outrossim, é a formulação para o desenvolvimento de métodos mais sofisticados de diagnóstico, tendo em vista a dificuldade, intrínseca em identificar alterações relacionadas ao AVC isquêmico em sua primeira fase mesmo com equipamentos como Tomografia Computadorizada (TC) sem contraste.

As modificações causadas pelo acidente vascular cerebral isquêmico são frequentemente muito sutis, o que torna sua detecção um desafio significativo para a análise visual. Estudos recentes indicam que, mesmo entre especialistas altamente treinados em radiologia, a sensibilidade para a identificação dessas lesões pode variar entre 45% e 55%. Esse dado evidencia a complexidade do diagnóstico precoce em casos de AVCi agudo, ressaltando a necessidade urgente de aprimoramento das técnicas de imagem e análise computacional, a fim de aumentar a precisão e a confiabilidade dos exames, permitindo a identificação precoce e a intervenção eficaz (LOPES et al., 2023).

Por fim, a utilização de medições volumétricas na detecção do acidente vascular cerebral isquêmico pode oferecer uma ferramenta crucial para a compreensão dos sinais precoces da patologia, bem como aos fatores de risco envolvidos. No Brasil,

dada a vasta extensão territorial, a presença de regiões isoladas e de difícil acesso, e a distribuição desigual de recursos médicos de alta qualidade, a ausência de especialistas em radiologia em diversos locais é uma realidade. Nesse cenário, ter algoritmos desenvolvidos para a detecção de AVC podem servir como ferramentas valiosas, auxiliando clínicos e outros profissionais de saúde na análise de imagens de TC . A rapidez na identificação das características das lesões por meio dessas tecnologias pode ser determinante para a escolha do tratamento adequado, oferecendo maior probabilidade de sucesso e melhor prognóstico para os pacientes.

Assim, a implementação e aprimoramento de algoritmos de detecção de AVC não só otimizam os processos diagnósticos, mas também têm o potencial de salvar vidas e melhorar a qualidade do atendimento médico em regiões carentes de especialistas.

1.2 OBJETIVOS

O presente trabalho tem como objetivo a identificação e classificação do Acidente Vascular Cerebral Isquêmico (AVCi) por meio de redes neurais artificiais, utilizando a arquitetura CNN e uma rede MLP.

1.2.1 Objetivos específicos

A partir do objetivo geral apresentado, destacam-se os objetivos específicos desta pesquisa:

- Estudar os aspectos teóricos do Acidente Vascular Cerebral Isquêmico;
- Implementar algoritmos de processamento digital de imagens;
- Aplicar técnicas de otimização para as redes neurais;
- Avaliar o desempenho dos algoritmos implementados;
- Documentar as fases do Acidente Vascular Cerebral isquêmico.

2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo estabelece a base teórica da pesquisa, ao abordar aspectos essenciais, delineando os principais tópicos e diretrizes fundamentais para o desenvolvimento deste projeto. O foco central do estudo recai sobre o cérebro, um órgão de importância vital para os seres humanos, pois é responsável por abrigar a totalidade de nossas funções cognitivas, intelecto e capacidade de raciocínio (RODRIGUES et al., 2023).

O acidente vascular cerebral (AVC) é uma condição médica séria que ocorre quando o suprimento de sangue para uma parte do cérebro é interrompido ou reduzido, privando o tecido cerebral de oxigênio e nutrientes. Esse evento pode levar à morte das células cerebrais em minutos, causando danos neurológicos significativos e, em casos graves, sequelas permanentes. Quando o AVC se manifesta de forma isquêmica (AVCI), que é o tipo mais comum, ele é provocado pela obstrução de uma artéria cerebral, geralmente devido à formação de coágulos sanguíneos ou placas de aterosclerose. Ambos os tipos de AVC podem resultar em défices funcionais, afetando a mobilidade, a fala, a memória e outras capacidades cognitivas e levar a morte (NETO et al., 2024).

A tomografia computadorizada (TC) é uma ferramenta diagnóstica de suma importância no contexto de AVCs. Ela permite a visualização detalhada do cérebro, auxiliando na distinção entre AVC isquêmico e hemorrágico, uma diferenciação crucial para determinar o tratamento mais adequado. A TC também possibilita a identificação da extensão e localização da lesão cerebral, contribuindo para uma intervenção rápida e precisa, fundamental para melhorar as chances de recuperação e minimizar as sequelas. A rápida execução e interpretação dos resultados da tomografia são fatores determinantes para o prognóstico dos pacientes acometidos por AVCs (MAGALHÃES et al., 2024).

Portanto, este capítulo destaca a importância da compreensão abrangente dos aspectos teóricos relacionados ao diagnóstico e intervenção em casos de AVC. A ênfase na patologia que afeta de forma crítica o cérebro e suas complexidades, reforça a relevância de um diagnóstico precoce e preciso. A tomografia computadorizada é apresentada como uma ferramenta indispensável, cuja aplicação eficiente pode impactar significativamente o prognóstico dos pacientes, maximizando as chances de recuperação e minimizando as sequelas. Assim, a fundamentação teórica discutida neste capítulo fornece um alicerce sólido para o desenvolvimento de práticas que busquem melhorar os desfechos clínicos relacionadas ao AVCi.

2.1 ESTADO DA ARTE

Esta seção contempla pesquisas e conceitos relacionados a detecção de AVCi utilizando técnicas de processamento digital, a partir de imagens de tomografia computadorizada. Foi feita uma revisão detalhada dos estudos mais recentes e, selecionados os de maior relevância para este trabalho.

Tabela 1 – Estado da arte.

Tema da pesquisa	Autores/Ano	Resumo
Redes Neurais na investigação de AVC por tomografia computadorizada	Silva, Carro e Costa (2019)	Este trabalho apresenta uma proposta de algoritmo capaz de identificar automaticamente a ocorrência do acidente vascular encefálico (AVC) usando imagens por tomografia computadorizada (TC). São definidos os métodos de segmentação por similaridade e morfologia matemática, além dos filtros de realce utilizados para modificar o histograma da imagem, que compreende os dados de entrada de uma rede neural Perceptron multicamadas, responsável pela classificação. Base de dados com 9 pacientes somando 450 imagens.
Deep Learning-Enhanced internet of medical Things to analyze Brain CT Scans of Hemorrhagic Stroke Patients: A new approach	Gao et al. (2020)	Este estudo propõe um sistema totalmente automático baseando em imagens de tomografia computadorizada do crânio através do aprendizado profundo de máquina classificando em AVC hemorrágico ou não. Base de dados não cita o número de pacientes, somente a quantidade 356 imagens.

Continua na próxima página

Tabela 1 – continuação

Tema da pesquisa	Autores/Ano	Resumo
Uso de Redes Neurais para a Predição de Diagnóstico de AVE: Uma Revisão Sistemática	Silva et al. (2022)	O objetivo desta revisão foi avaliar como as redes neurais artificiais estão sendo utilizadas para a predição de diagnóstico de AVE. Trata-se de uma revisão sistemática de artigos indexados nas bases de dados PubMed, BVS, SciELO, Cochrane e Springer-Link, entre janeiro e fevereiro de 2022. Os critérios de inclusão e filtros para esse trabalho foram: artigos relacionados ao tema, estudos randomizados, coorte e ensaios clínicos, trabalhos em humanos, realizados nos últimos 5 anos, apenas nos idiomas Português, Inglês e Espanhol e com texto completo disponível gratuitamente. Os parâmetros de exclusão foram: artigos duplicados, fuga ao tema, artigos de revisão e trabalhos que não preencham todos os critérios de inclusão.
Tomografia computadorizada de perfusão cerebral no AVC isquêmico: previsão do ASPECTS final através dos valores de core e penumbra	Monteiro et al. (2021)	Tratou-se de um estudo retrospectivo cujos casos clínicos foram recolhidos da base de dados do Hospital de Beatriz Ângelo (Loures, PT), com fundamento em critérios de inclusão pré-definidos. Após a aquisição da tomografia computadorizada de perfusão (PCT) a uma amostra de 17 doentes, admitidos através do programa Via Verde AVC, foi realizado o pós-processamento com recurso ao software syngo.via (aplicação Neuro Perfusion). Os dados resultantes dos mapas de perfusão foram analisados estatisticamente através da aplicação, permitindo uma análise que considerou os valores de CBF e respetivos volumes de <i>core</i> e <i>penumbra</i> .

Continua na próxima página

Tabela 1 – continuação

Tema da pesquisa	Autores/Ano	Resumo
Técnicas de Inteligência artificial para diagnóstico de Acidente Vascular Cerebral através de imagens e dados textuais sobre possíveis vítimas	Pilan (2023)	Este trabalho abordou essa questão, aplicando técnicas de Aprendizado de Máquina e Aprendizagem Profunda, sendo ambas subáreas da Inteligência Artificial, a qual vem sendo amplamente aplicada em diversos segmentos na busca de otimizar tarefas, principalmente no diagnóstico de doenças. Modelos classificadores de fatores de risco foram criados a partir da aplicação dos modelos de Regressão Logística e Floresta Aleatória, assim como uma Rede Neural Convolucional (CNN) para classificação de imagens de tomografia computadorizada da região cerebral.

Em Silva, Carro e Costa (2019), foi utilizada uma base de dados com 9 pacientes, rotulados em isquemia, hemorragia e saudável que somam no total 450 imagens. Linguagem Java e *Python*, seu resultados foram 98,51% para rede *MLP+* Difusão Anisotrópica. O número de imagens de cada paciente não foi especificado a análise levou em consideração informações sobre idade e sexo dos pacientes. O processamento de imagem incluiu operações de erosão, dilatação e fechamento. Na etapa de segmentação, foi aplicada limiarização e foram utilizados filtros de suavização, como o filtro de difusão anisotrópica, o filtro Kuwahara e o filtro Gaussiano. Além disso, foi utilizado o histograma para auxiliar na análise das imagens, para extração de calota craniana utilizou o mesmo método que Aguiar (2017).

Já em Gao et al. (2020) foi feito a extração com 120 arquivos para AVC o método classifica e faz segmentação automática do AVCh, a linguagem escolhida foi *Python* 3.0, alcançando uma especificidade de 99,93%, não é descrito o valor da acurácia.

No trabalho de Pilan (2023), sua base de dados foi retirada da plataforma *Kaggle* com 5.110 registros rotulados como AVC ou não, linguagem *Python*. O objetivo desde trabalho foi identificar a ocorrência de AVC ou não foram analisadas 299 imagens com AVC e 174 sem, obteve um resultado de 73,33%.

Em Merdas (2024) O estudo propõe o modelo *Elastic Net*, *MLP* e *SMOTE*, que combina três técnicas, para prever a ocorrência de AVC. O *Elastic Net* realiza a seleção de características importantes, como a identifica de relações complexas e não

lineares nos dados, enquanto o *MLP* classifica os dados de um conjunto abrangente de informações sobre AVC. O *SMOTE* é utilizado para melhorar o desempenho do modelo. O modelo EMS obteve uma precisão de 95% e um erro quadrático médio (MSE) de 0,05, ajudando a prever o AVC com base nos dados históricos dos pacientes. Neste estudo, foi utilizado um conjunto de dados de código aberto proveniente do Kaggle especificamente relacionado ao AVC. Além disso, utilizou metadados como identificação do paciente, gênero, idade, hipertensão, doenças cardíacas, se já foi casado, tipo de trabalho, tipo de residência, nível médio de glicose, IMC, status de tabagismo. obteve uma precisão de 95%.

Em Sarmiento (2021) É proposto um estudo com abordagem para segmentação de AVC utilizando tomografia computadorizada. As etapas envolvem aquisição de imagens, segmentação da região de interesse (ROI), extração de características e aprendizado de máquina. A base de dados usada contém 420 imagens de tomografias cerebrais, com 140 imagens de cérebros saudáveis e 280 de AVCs. Técnicas de pré-processamento, como suavização e segmentação, foram aplicadas para identificar a região cerebral. A extração de características foi feita utilizando vários métodos como Momentos Estatísticos, Momentos de *Zernike*, *GLCM* e *LBP*, sua acurácia é de 98%.

Em suma, a utilização de redes neurais artificiais para tratamento, segmentação e identificação de características em imagens médicas tem sido amplamente utilizada e pesquisada no mundo todo.

No trabalho de Silva, Carro e Costa (2019) é proposto um algoritmo capaz de identificar automaticamente a ocorrência do acidente vascular encefálico (AVC) usando imagens por tomografia computadorizada (TC). São definidos os métodos de segmentação por similaridade e morfologia matemática, além dos filtros de realce utilizados para modificar o histograma da imagem, que compreende os dados de entrada de uma rede neural Perceptron multicamadas, responsável pela classificação.

Em Gao et al. (2020) a proposta é um sistema totalmente automático baseado em imagens de tomografia computadorizada do crânio, através do aprendizado profundo de máquina, classificando em AVC hemorrágico ou não. O modelo consiste em redes de aprendizagem profunda capazes de detectar a existência de acidente vascular cerebral hemorrágico contido na imagem, combinado com o Rede *Mask R-CNN* especializada no mapeamento de AVC, o modelo segmenta a região afetada e combina diferentes aprendizados profundos de máquina. A base de dados não cita o número de pacientes, somente a quantidade 356 imagens e quantidade de arquivo que foram 120.

No trabalho de Silva et al. (2022) faz a avaliação como as redes neurais artificiais estão sendo utilizadas para a predição de diagnóstico de AVC. Trata-se de uma revisão

sistemática de artigos indexados nas bases de dados *PubMed*, *BVS*, *SciELO*, *Cochrane* e *SpringerLink*, entre janeiro e fevereiro de 2022. Os critérios de inclusão e filtros para esse trabalho foram: artigos relacionados ao tema, estudos randomizados, corte e ensaios clínicos, trabalhos em humanos, realizados nos últimos 5 anos, apenas nos idiomas Português, Inglês e Espanhol e com texto completo disponível gratuitamente. Os parâmetros de exclusão foram: artigos duplicados, fuga ao tema, artigos de revisão e trabalhos que não preenchiam todos os critérios de inclusão, todos os resultados da revisão são acima de 73% .

O trabalho de Pilan (2023), discorre sobre a aplicação de técnicas de Aprendizado de Máquina e Aprendizagem Profunda, sendo ambas subáreas da Inteligência Artificial, a qual vem sendo amplamente aplicada em diversos segmentos na busca de otimizar tarefas, principalmente no diagnóstico de doenças. Modelos classificadores de fatores de risco foram criados a partir da aplicação dos modelos de Regressão Logística e Floresta Aleatória, assim como uma Rede Neural Convolutiva (CNN) para classificação de imagens de tomografia computadorizada da região cerebral.

As técnicas empregadas nas pesquisas relacionadas à detecção de AVCi a partir de imagens de tomografia computadorizada revelam avanços significativos em metodologias de processamento digital e aprendizado de máquina. A partir da análise, conclui-se que os métodos abrangem desde técnicas clássicas de pré-processamento até modelos sofisticados de redes neurais e abordagens integradas. Em síntese, os avanços mostram que redes neurais e abordagens híbridas estão otimizando a identificação de AVC, destacando-se pela precisão elevada e capacidade de generalização. No entanto, desafios como padronização de dados e reprodutibilidade científica permanecem relevantes.

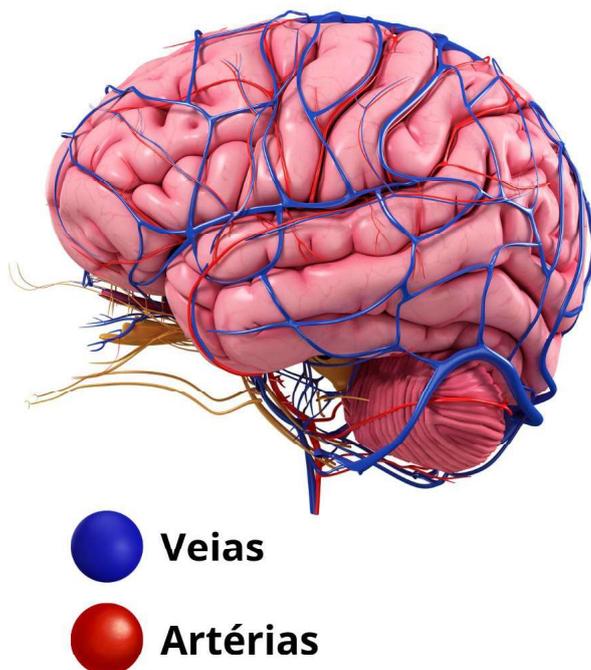
2.2 O CÉREBRO

Neste tópico, serão abordadas de forma detalhada as principais características anatômicas e fisiológicas do cérebro, elementos fundamentais para compreender suas funcionalidades complexas e essenciais para o corpo humano.

O cérebro, uma estrutura altamente especializada e sofisticada, é o órgão mais importante do sistema nervoso central, responsável por coordenar uma vasta gama de processos vitais, desde funções básicas, como a respiração e o controle dos batimentos cardíacos, até atividades cognitivas superiores, como pensamento, memória, aprendizado e emoções. Apesar de ser pequeno anatomicamente, ele utiliza cerca de 20% da energia do corpo, e ele é quem proporciona capacidades como raciocínio, memória, criatividade, afeto, além de outras funções essenciais para a vida e sua evolução (MONTANA; JÚNIOR, 2024).

Cercado por ramos, artérias e milhares de vasos sanguíneos que fornecem sangue ao cérebro, como mostrado na Figura 1, como pequenas tubulações nas as cores vermelha (artérias) e azul (veias). Esses ramos arteriais são cruciais para garantir que o cérebro receba oxigênio e nutrientes suficientes para funcionar corretamente. Qualquer dano nessa rede de vasos por menor que seja pode causar problemas severos (MARCHI et al., 2024).

Figura 1 – Cérebro, veias e artérias.



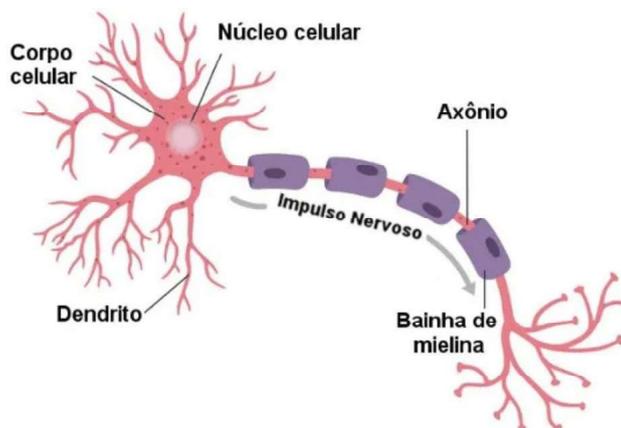
Fonte: Aatoria Própria.

O sangue é levado até o cérebro principalmente pelas veias jugulares e artérias carótidas. Quando há atividade neuronal há também um aumento no fluxo de sangue e qualquer breve interrupção desse fluxo pode causar inconsciência. De maneira geral, uma interrupção nesse fluxo por um ou dois minutos que seja, prejudica as funções neuronais e a falta de oxigênio total, por 4 minutos, provoca lesões permanentes, ou seja, a morte do neurônios da região afetada por falta de oxigênio (MAGALHÃES et al., 2023).

A principal célula cerebral é o neurônio. A rede de neurônios forma o Sistema Nervoso Central (SNC) que é a rede de comando do nosso corpo, sua estrutura básica é a célula neuronal, composta pelo corpo celular, que contém o núcleo e é responsável por manter a célula funcional. Dendritos, que são extensões ramificadas que se projetam do corpo celular, recebem sinais elétricos e químicos de outros neurônios. O axônio que é uma longa extensão que a condução de impulsos elétricos para outras células garantindo o fluxo correto do sinal, no final do axônio, encontramos os terminais

sinápticos, que liberam neurotransmissores para comunicar-se com outros neurônios ou células musculares. A bainha de mielina, que cobre o axônio em segmentos, é uma membrana lipídica, que atua como isolante elétrico e permite que os impulsos nervosos sejam conduzidos com velocidade e precisão, sua estrutura esta exemplificada na Figura 2 (EDUCAÇÃO, 2023).

Figura 2 – Forma estrutural básica de um neurônio.



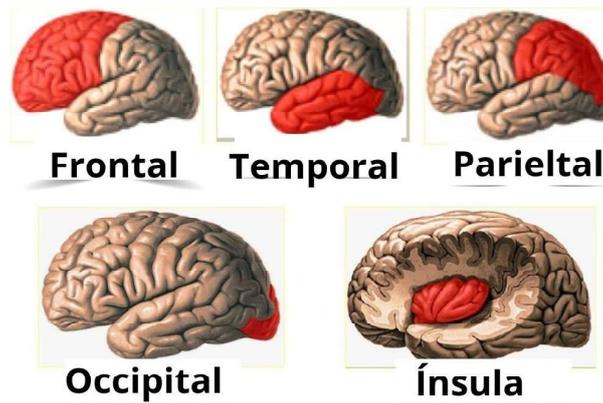
Fonte: Adaptado de Educação (2023)

O neurônio humano é uma célula nervosa especializada, essencial para a comunicação do sistema nervoso e sem a comunicação neuronal somos incapazes de pensar e agir. Essas transmissões complexas controlam todas as tarefas e de nosso corpo e regulam o funcionamento dos órgãos internos e nossas emoções. As sinapses, nome dado a essa transmissão acontecem uma velocidade incrivelmente alta, 200m/s (ABRAHÃO, 2024).

As doenças neurológicas são patologias que incidem sobre o sistema nervoso central (SNC), impactando de maneira significativa tanto as funções motoras quanto cognitivas. Essas condições comprometem a execução das atividades cotidianas mais elementares, afetando a autonomia do indivíduo e sua capacidade de interagir adequadamente com o ambiente. Ademais, muitas dessas doenças podem ter repercussões progressivas, acarretando uma deterioração gradual da qualidade de vida e exigindo abordagens terapêuticas multifacetadas para atenuar os deficit funcionais e promover o bem-estar do paciente (SILVA; PEREIRA, 2021).

A divisão dos lobos cerebrais é fundamental para a organização e funcionamento do cérebro, permitindo a especialização e a eficiência das funções cognitivas e sensoriais. Cada lobo cerebral está dividido e destacado em vermelho na Figura 3, o frontal, temporal, parietal, occipital e ínsula, desempenham funções específicas, como caminhar, falar, ouvir e pensar. (SCORZA et al., 2024).

Figura 3 – Lobos cerebrais.



Fonte: Autorial Própria.

2.2.1 Lobos cerebrais

Quando uma patologia degenerativa como Alzheimer, um traumatismo craniano ou um acidente vascular cerebral isquêmico atinge um ou mais lobos cerebrais as consequências podem ser irreversíveis. Abaixo será listado os lobos cerebrais e algumas consequências que comprometem a vida do ser humano, caso eles sejam afetados com a falta de nutrientes ou oxigênio (PAULSEN; WASCHKE, 2023)

- Lobo frontal: É envolvido no planejamento, controle motor voluntário, funções executivas, tomada de decisão e comportamento social. Lesões nessa área podem afetar a personalidade e a capacidade de planejar ou a tomada de decisões e interação social.

Danos ao lobo frontal podem ter impactos profundos e variados, dependendo da extensão e localização do dano. Lesões podem resultar em dificuldades com controle motor, alterações de personalidade, comportamentos desinibidos, problemas com planejamento e tomada de decisões, além de dificuldades com a fala e linguagem. Condições como a doença de Alzheimer, a demência fronto-temporal, traumas cranianos e AVCi, muitas vezes afetam o lobo frontal, levando a alterações significativas na vida de uma pessoa. A complexidade e a importância do lobo frontal tornam-o uma área-chave para a compreensão das funções cerebrais superiores e para o tratamento de muitas condições neurológicas e psiquiátricas (RODRIGUES et al., 2024).

- Lobo temporal: Localizado nas laterais dos hemisférios cerebrais, aproximadamente atrás das orelhas, é uma área fundamental para várias funções cognitivas e sensoriais, incluindo audição, compreensão da linguagem, memória e reconhecimento de padrões visuais e auditivos.

O córtex auditivo primário que fica localizado no giro temporal superior é responsável pelo processamento inicial dos sinais auditivos. É onde os sons são analisados em termos de frequência, volume e outras propriedades básicas. Além da audição básica, o lobo temporal é crucial para o reconhecimento de padrões sonoros complexos, como a música e a fala. Danos nessa área podem levar a surdez total. Além disso, tem-se o hipocampo que também tem parte de sua estrutura localizada nessa área, mais para a medial do lobo temporal, ele é essencial para a formação de novas memórias e para a navegação espacial, desempenha um papel central na memória episódica, que é a recordação de eventos pessoais e experiências, e se atingido por algum advento essa área pode levar o paciente a condições de perda da memória. (MELO et al., 2023).

- Lobo parietal: É uma região essencial do cérebro, localizada na parte superior e central de cada hemisfério cerebral, atrás do lobo frontal e acima do lobo temporal. Ele desempenha um papel crucial no processamento sensorial, percepção espacial, coordenação motora e integração de informações de diferentes sentidos. É dividido em várias regiões, incluindo o giro pós-central, que contém o córtex somatossensorial primário, e o lóbulo parietal superior e inferior, que têm diferentes funções cognitivas e sensoriais. Se essa área for afetada o paciente pode perder domínio de suas ações motoras e ficar sem andar ou mexer os braços (CRESPI; NORO; NÓBILE, 2020).
- Lobo occipital: É a menor das quatro regiões principais do cérebro, localizado na parte posterior dos hemisférios cerebrais. Sua função principal é o processamento da informação visual, sendo crucial para a percepção e interpretação de tudo o que os seres humanos enxergam. Embora seja pequeno, o lobo occipital é extremamente importante para a capacidade de perceber e compreender o mundo visual.

Ele trabalha em conjunto com o lobo temporal para ajudar no reconhecimento de objetos. As informações visuais básicas são enviadas para o lobo temporal, onde são comparadas com memórias anteriores para identificação. Contribui também para a percepção de movimento e a noção de profundidade, que são cruciais para a navegação e interação com o ambiente.

As informações visuais processadas no lobo occipital são integradas com outros sentidos e sistemas motores para guiar ações, como o movimento dos olhos e da cabeça em direção a estímulos visuais. Participa de reflexos como o reflexo de piscamento, que protege os olhos de objetos que se aproximam rapidamente. Danos ao lobo occipital podem levar a uma série de distúrbios visuais, dependendo

da gravidade e localização da lesão como cegueira cortical ou a visualização de alucinações (FARIA et al., 2024).

- **Ínsula:** Também conhecida como ínsula cerebral, é uma região oculta do cérebro localizada profundamente dentro do sulco lateral (fissura de *Sylvius*), que separa os lobos temporal, frontal e parietal. Apesar de sua localização interna, a ínsula desempenha papéis essenciais em diversas funções cognitivas, sensoriais e emocionais. A ínsula é crucial para a percepção das sensações internas do corpo, como fome, sede, dor visceral, batimentos cardíacos e estado geral de bem-estar, isso ajuda na manutenção da homeostase.

Também está envolvida na experiência e na regulação de emoções, incluindo sentimentos de empatia, nojo e aversão. Existe uma conexão profunda da ínsula com a amígdala, trabalham em conjunto para processar respostas emocionais e comportamentos associados.

Os comportamentos de vício e compulsão são associada a mecanismos de recompensa e punição, desempenhando um papel em comportamentos de vício e compulsivos também trabalhados pela ínsula. Danos ou disfunções na ínsula podem levar a diversas condições neurológicas e psiquiátricas, incluindo transtornos emocionais, doenças como depressão, ansiedade e distúrbios de percepção corporal.

A ínsula é uma região multifuncional que integra sensações internas com processos emocionais e cognitivos, desempenhando um papel crucial na forma como percebemos a nós mesmos e interagimos com o ambiente. Sua importância na regulação emocional, na percepção corporal e na tomada de decisões a torna uma área vital para o funcionamento saudável do cérebro (GOLDSTEIN; NAGLIERI, 2023).

2.3 DIVISÃO ANATÔMICA RADIOLÓGICA

Na medicina, além da divisão anatômica tradicional, existe também uma divisão radiológica, que é amplamente usada para diagnósticos, laudos, estudos e tratamentos. Essa divisão em planos radiológicos serve como uma referência essencial para o médico radiologista ao elaborar os laudos, pois permite identificar e visualizar estruturas internas com maior precisão. Com base nesses planos, é possível realizar reconstruções em 3D das áreas examinadas, o que facilita uma avaliação detalhada e contribui para um diagnóstico mais preciso (PESCININI; VICTORINO; COCLETE, 2023).

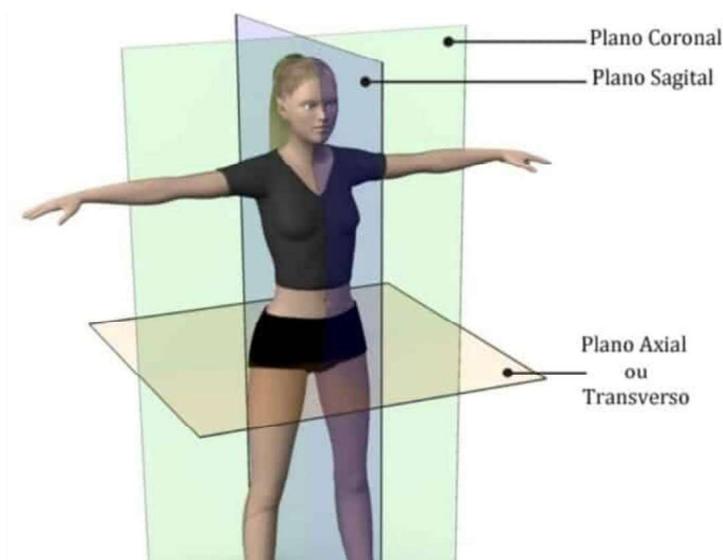
O corpo humano constitui um sistema integrado e harmonioso, composto por partes organizadas e interconectadas de maneira precisa. A ciência, ao aprofundar-se

no estudo do organismo, estabelece padrões e propõe classificações de acordo com concepções fisiológicas e anatômicas. Dessa forma, o corpo é subdividido em três principais planos anatômicos, que facilitam o entendimento das estruturas internas e seu funcionamento, permitindo uma análise sistemática e detalhada das relações entre seus componentes. Os planos principais são axial, sagital e coronal (MORAES, 2024).

- O plano Axial, corta o objeto de estudo ao meio de forma que a leitura seja feita com vista superior e inferior;
- O plano Sagital, divide o objeto ao meio, porém sua visualização se dará da direita para esquerda;
- O plano Coronal, possibilita uma visão anterior e posterior do objeto.

Os três planos são utilizados em todos os setores de diagnóstico por imagem, esses planos e são tomados como referência para descrever a localização de estruturas e orientações no corpo humano, sendo assim é utilizado por toda a área da saúde, não só a medicina. Na Figura 4, tem-se uma ilustração de como é realizada essa divisão.

Figura 4 – Divisão anatômica radiológica.



Fonte: Monteiro et al. (2021)

Em exames de imagens por tomografia computadorizada a aquisição pode ser realizada apenas em um único plano, o axial. Posteriormente pode-se reconstruir essas imagens também nos outros dois planos, o coronal e o sagital, com a compreensão dos

planos e cortes consegue-se ter uma compreensão melhor da localização dos órgãos e ossos. Pode-se também, realizar reconstruções 3D de qualquer área e planejar cirurgias de forma mais segura e eficaz.

Esses planos e eixos são utilizados habitualmente pela comunidade científica, podendo-se destacar exames de imagens que manipulam reconstruções 3D, como tomografia, ressonância magnética e ultrassonografia, que utilizam tais cortes e planos para planejamento e mensuração de medidas (AL-RAMMAHI et al., 2023).

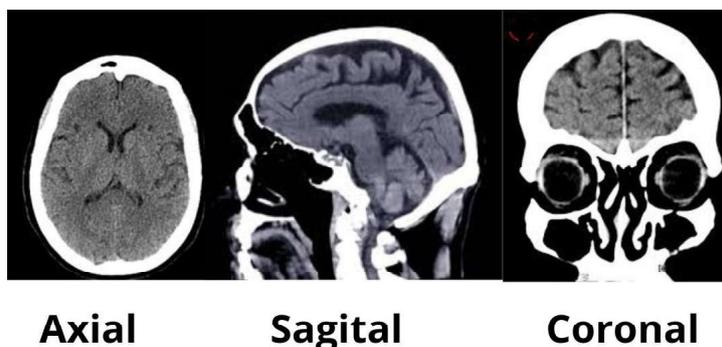
Na Figura 5, são apresentados os três planos na visão radiológica por meio de imagens obtidas através da tomografia computadorizada, extraídas da base de dados deste projeto. A imagem axial representa cortes transversais que permitem visualizar as seções superior e inferior do objeto em questão, demonstrando, neste caso, uma fatia do crânio humano.

Por sua vez, a imagem sagital é caracterizada por cortes que proporcionam uma visão do objeto de direita para esquerda, evidenciando as estruturas da face e do crânio.

Finalmente, a imagem coronal oferece uma perspectiva que abrange as partes anterior e posterior, permitindo a visualização da face e da região frontal do crânio.

Essas diferentes projeções são fundamentais para uma análise compreensiva das estruturas craniofaciais e suas inter-relações (SILVA et al., 2024).

Figura 5 – Divisão anatômica radiológica por TC.



Fonte: Autoria Própria

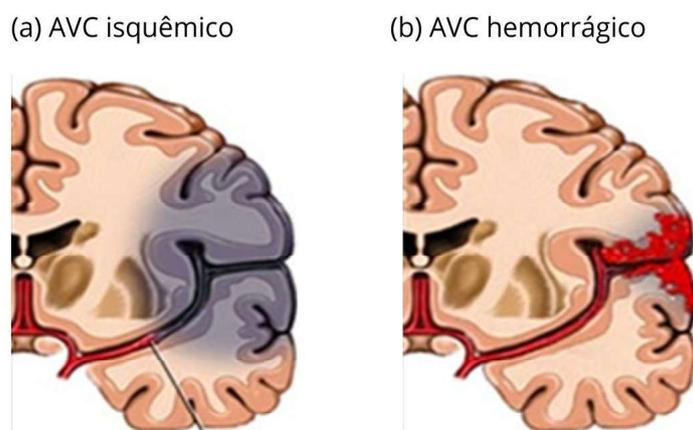
2.4 ACIDENTE VASCULAR CEREBRAL

Segundo o documento, *The Burden of Stroker in Europe*, da *Aliance for Europe* (American Stroke Foundation, 2024), o AVC é definido como uma doença aguda e cerebral, que causa morte e incapacidade severa de origem vascular, onde a falta de oxigenação para os vasos cerebrais leva a danos neuronais da região afetada, que com o passar das horas atinge a severidade, ou seja, morte dos neurônios.

Existem duas classificações para AVC, o acidente vascular hemorrágico (AVCh) e o acidente vascular isquêmico (AVCi), ambos com elevada taxa de mortalidade e incapacidade, ocorrendo em todos os sexos e idade, apesar do sexo masculino acima dos 45 anos serem os mais afetados. O AVCh, ocorre quando há rompimento de um vaso cerebral, provocando hemorragia. Essa hemorragia pode acontecer dentro do tecido cerebral ou na superfície entre o cérebro e as membranas que fazem parte da proteção do sistema nervoso central, as meninges. Tal tipo é responsável por 15% de todos os casos de AVC.

O AVCi ocorre quando há obstrução de uma artéria, que pode ser causada por um êmbolo ou placas de gordura que se soltam da origem e migram até o cérebro pelos vasos sanguíneos impedindo a passagem de oxigênio para células cerebrais, que acabam morrendo (ALMEIDA et al., 2024). Na Figura 6, é demonstrado um exemplo ilustrativo de como os dois tipos de AVC se comportam dentro da massa cerebral, o hemorrágico extravasando para dentro da calota e o isquêmico causando morte neuronal por falta de oxigênio.

Figura 6 – Os dois tipos de AVC.



Fonte: Autoria Própria.

O AVCi é o mais comum e representa 85% de todos os casos, causando óbitos, incapacidades leves, moderadas ou severas, e acontece com maior frequência em homens acima de 50, porém nos últimos anos há um aumento em pacientes femininas e mais jovens, dentro da faixa etária de 15 a 35 anos (BRASIL, 2019).

O tratamento de AVCi segue a necessidade de associação da imagem obtida com o estado clínico do paciente, uma vez que de acordo com a diretriz terapêutica para tratamento do AVCi proposto pelo ministério da saúde, se o usuário em questão apresenta sinais clínicos tais como: desvio de rima labial, disartria, parestesia e/ou redução do nível de consciência de forma aguda, associada à TC normal, o médico deve tratar o caso como AVCi o mais rápido possível. Se esse paciente esti-

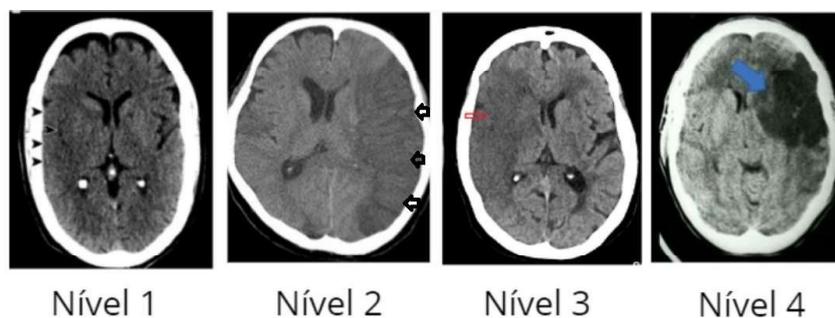
ver dentro da janela de oportunidade que são nas 5 primeiras horas, onde deve-se realizar trombólise com alteplase, tenecteplase ou estreptoquinase. Em casos onde os sintomas se iniciaram há mais de 24 horas o manejo será apenas conservador (fisioterapia/fonoaudiologia), quando possível (CABRAL et al., 2024).

2.4.1 Níveis de isquemia

O AVCi, tema deste trabalho, também apresenta níveis, também chamado de fases, com respectivas gravidades por tempo de lesão. A gravidade está diretamente relacionada ao tempo de ação da anormalidade. Quanto maior o tempo, maior a possibilidade de sequelas graves e até óbito, por isso quanto mais rápido o paciente tiver o diagnóstico maior a será chance de reversão das sequelas. O cérebro pode apresentar AVCi em qualquer parte, sendo mais comum próximo aos ventrículos ou na área do córtex para o interior cefálico (MARIANELLI, 2020).

A Figura 7, demonstra as quatro fases do AVCi, e a diferença dos tons de cinza da área afetada em imagens de tomografia computadorizada, e como a cada fase a área afetada escurece na imagem, demonstrando com maior nitidez a processo de degradação neuronal.

Figura 7 – Os quatro níveis de isquemia de um AVC.



Fonte: Autoria Própria.

O primeiro nível de AVCi em imagens de tomografia computadorizada, a área afetada apontado pelas setas, (Nível 1) na Figura 7, observa-se uma suave diferenciação dos sulcos cerebrais, onde há demonstração de homogeneidade, quando comparadas ao lado esquerdo. O apagamento dos sulcos corticais também é notado, porém de forma leve, ainda pode-se observar o desaparecimento da ínsula e fissura e Hipotensidades focais. Porém, percebe-se que a diferença é tão sutil que quase fica imperceptível. Tal nível de isquemia é classificado como hiperagudo precoce, apontando para um AVCi que é 0 a 6 horas da sua ação inicial. Essa fase é ideal para o tratamento, pois nas primeiras 6 horas os danos ainda são reparáveis (GUERREIRO, 2023).

O segundo nível, ou hiperagudo tardio, ocorre no intervalo de 6 a 24 horas, apresenta hipodensidade maior e sequelas permanentes no indivíduo. Na imagem é perceptível o pagamento dos sulcos corticais mais acentuado.

A isquemia entre 24 horas e 7 dias é classificada como aguda, Nível 3. Esse nível pode ser letal ou com sequelas graves de incapacidade permanente. A coloração cinza homogênea que com o passar das horas escurece para um tom cada vez mais negro, subindo na escala negativa de cores, e tornando-se cada vez mais visível sendo assim é demonstrado esse avanço no hemisfério esquerdo do paciente que está notoriamente lesionado, com as áreas do sulcos corticais apagadas evidenciando morte neuronal (SALES et al., 2023).

A isquemia crônica de Nível 4 é classificada como uma condição grave, caracterizada pela ausência de probabilidade de reversão. Essa manifestação clínica torna-se perceptível após um período de duas semanas. Neste estágio, as lesões resultantes da isquemia são evidentes e podem ser identificadas com relativa facilidade, dispensando a necessidade de ferramentas de análise sofisticadas. Essa clareza na apresentação das lesões destaca a gravidade da condição e a urgência de intervenções clínicas adequadas (SILVA; ALMEIDA, 2020). A coloração enegrecida a quase -800 HU, demonstra a área morta, e a tomografia é utilizada para controle de lesão e não mais diagnóstico.

A Escala de Hounsfield (HU), assim como a tomografia computadorizada serão explanadas na próxima seção. O entendimento desses dois tópicos são essências para este trabalho e para futuros projetos, sendo necessário compreender de forma clara como ambos funcionam e sua atribuições.

2.5 TOMOGRAFIA COMPUTADORIZADA

A Tomografia Computadorizada (TC), foi desenvolvida em 1970, utiliza radiação X para aquisição de imagens. Ela apresenta-se como exame mais solicitado para investigação de AVCi pelo seu baixo custo e acessibilidade, quando comparada a ressonância magnética, e o seu desenvolvimento foi primordial para diagnósticos de doenças cerebrais (DESCATTO, 2023).

Criada pelo engenheiro eletricista *Goldfrey Newbold Hounsfield*, antes da versão mais recente (tomografia *multislices*) disponível no mercado, a TC passou por evoluções conhecidas como as seis gerações da tomografia computadorizada (BOTTEGA et al., 2023).

A primeira geração de tomógrafos foi desenvolvida no início dos anos 1970 e é conhecida como geração de tomógrafos de feixe fino ou geração de feixe único. Esses

aparelhos utilizavam um feixe de raios X linear que atravessava o corpo do paciente em um único plano. O tubo de raios X e o detector se moviam em conjunto, realizando um movimento de translação e rotação ao redor do corpo, registrando as diferenças de densidade dos tecidos para formar uma imagem em corte da área analisada. Essa tecnologia permitiu as primeiras imagens transversais do corpo humano, mas o processo era lento e limitado em resolução (AMARAL; CAIXETA, 2024).

Em 1974 surge a segunda geração com características técnicas similares às dos aparelhos da primeira geração. Entretanto, melhorias se destacaram nessa geração, tais como a utilização de mais 30 detectores adjacentes e a forma do feixe, que passou a ser mais aberta em forma de leque, o que diminuiu significativamente o tempo de aquisição, reduzindo da ordem de minutos para em média 15 segundos. Houve também, um aumento da resolução espacial, porém a taxa de dose de radiação era muito alta e o aparelho foi proibida (MOURÃO, 2015).

A terceira geração se apresenta entre os anos 1975 e 1977. Tal geração trouxe consideráveis alterações em relação a anterior, os tubos de raio X e os detectores do aparelho deixaram atuar com movimentações lineares, passando a ter movimentação de 360° em torno de um objeto. A quantidade de detectores aumentou para até 960, reduzindo ainda mais o tempo de cada varredura, para 2 a 5 segundos. O feixe foi ampliado, porém ainda existiam limitações, os cabos que faziam a rotação do tubo de raio-x apresentavam constantes problemas pelos giros de 360°, e a mesa de exame ainda não era simultânea com o tubo de raio X (DESCATTO, 2023).

A quarta geração, por sua vez, surge em 1981, apresentando certa similaridade com a tecnologia implementada na terceira geração, contudo implementou-se um aumento no número de detectores, de 2000 a 4.800, que tornou-se uma inovação quando aliada a tecnologia de anéis deslizantes, permitindo uma rotação contínua e consequentemente eliminando os cabos de alimentação (SIMÃO, 2021).

A quinta e a sexta geração são as tecnologias atualmente utilizadas e trazem ainda mais melhorias, tais como, a mesa e tubo em andamento simultâneo para melhor reconstrução da imagem e diminuição de artefatos de movimentos. Ainda assim, a helicoidal de quinta geração e *multislices* de sexta possuem características diferentes. A tomografia helicoidal é caracterizada por realizar uma hélice em torno do corpo ao invés de uma sucessão de círculos, isto é, a mesa de paciente, ao invés de ficar parada durante o corte e captação das imagens, avança continuamente em torno dele. Desta forma, as informações são captadas de maneira contínua com a reconstrução de imagens de qualquer *slice* analisado (FLOHR, 2022).

A tomografia *multislice* é caracterizada por suas múltiplas fileiras de detectores, desta forma, ela é capaz de adquirir simultaneamente quatro cortes de imagens com

baixo tempo de aquisição (0,5 s). Além disso, a baixa dose de radiação e a redução no tempo do exame também são características importantes da tomografia *multislice*.

A característica mais importante da TC é a considerável sensibilidade da técnica aplicada, permitindo que tecidos moles como massa cinzenta e massa branca possam ser claramente diferenciados. Essa técnica também permite medir, de forma acurada, os valores de absorção de cada tecido, possibilitando a natureza do tecido em estudo a partir da atenuação da radiação, quanto mais denso o tecido mais atenua a radiação, isso é possível graças a escala *Hounsfield* (HSIEH, 2022).

2.5.1 Escala Hounsfield

A análise de tons de cinza das imagens, por meio de tomografia computadorizada, para avaliar densidade das estruturas do corpo humano é feita pela medição dos valores de Unidades *Hounsfield* (HU), um modelo comparativo em que se utiliza uma escala com valor definido e a partir da sua alteração pode-se obter classificações de doenças, anomalias e variações anatômicas (BOTTEGA et al., 2023).

Utiliza-se tal escala como ponto principal de referência. O valor de cinza mais homogêneo é representado pela densidade da água, como pode ser visualizado na Figura 8, representado pelo número zero, o extremo direito representado pela numeração mil, indica os materiais rígidos e de alta densidade, que por sua vez, devido a não penetração da radiação se apresentam na cor branca. No extremo esquerdo têm-se a representação dada por menos mil, que na coloração é o preto puro, definindo baixa densidade (DURÁN; NAVAS; SÁNCHEZ, 2024).

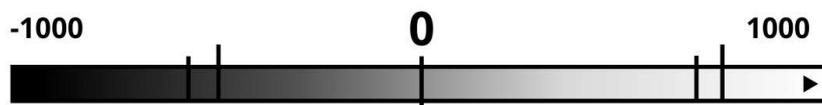
Os valores são distribuídos conforme a densidade do tecido, quanto mais denso, mais segue para a cor branca, quanto menos denso mais segue para o tom escuro dentro da escala. Existe uma tabela universal que segue os valores listado (AGUIAR, 2017).

1. Osso: 800 a 1000 HU
2. Massa cinzenta: -32 a 41 HU
3. Massa branca: -23 a 34 HU
4. Gordura: -60 a -100 HU
5. Pulmão: -900 a -600 HU

A escala de *Hounsfield* é utilizada universalmente, para tomógrafos de fabricantes do mundo inteiro, isso facilita a padronização de imagem e a localização de

patologias através da diferença de densidade. O valor que representa a patologia de AVCi, fica em torno de 6 a 25 HU (SARMENTO, 2021).

Figura 8 – Escala Hounsfield.



Fonte: Autoria Própria.

2.5.2 Imagem DICOM

O crescente uso da TC nos anos 70, bem como o avanço computacional para aplicações clínicas, potencializou a necessidade de estabelecer regras. Dessa forma a comissão ACR-NEMA (*American College of Radiology - National Electrical Manufacturers Association* – Universidade Americana de Radiologia - Associação Nacional dos Fabricantes Elétricos) reconheceu a necessidade emergente de padronizar dados, transferências de imagens e informações associadas, entre os dispositivos e os usuários (MACKENZIE; LEWIS; LOVELAND, 2023).

O padrão surge para sanar tal problemática, apresentando um único modelo de envio e leitura, chamado *Digital Imaging and Communications in Medicine (DICOM)*. O padrão DICOM estabelece as regras possibilitando que imagens médicas e informações associadas sejam trocadas entre todas as redes de computadores e hospitais.

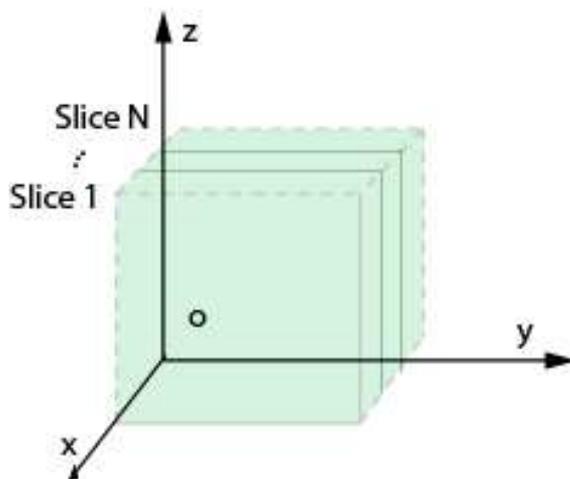
Por designar uma linguagem comum entre os equipamentos, independente de sua marca, otimiza o diagnóstico e o processamento desses dados. A TC armazena imagens no padrão DICOM, é um arquivo carregado com um volume de *Slice* que são fatias de imagens, Figura 9.

Cada pixel dessa imagem é formado por 16 *bits*, 4 *bits* de informação textual e 12 *bits* de exibição. O valor de atenuação de um pixel é localizado e expresso em unidades de *Hounsfield* (UH), que se relaciona ao nível de cinza da imagem DICOM.

A configuração do redimensionamento de inclinação (*m*) e de interceptação (*a*) encontram-se nas informações textuais da imagem DICOM e, tipicamente, possuem os valores de 1 para a inclinação e de -1024 para a interceptação, isso para todos e quaisquer volume DICOM (MIRANDA-VIANA et al., 2023). O intervalo dinâmico da UH é amplo, de -1000 UH até 1000 UH (AGUIAR, 2017).

Além dos os dados da imagem, um arquivo DICOM também traz outras informações no seu cabeçalho, tais como:

Figura 9 – Representação imagem DICOM.



Fonte: Autoria Própria.

- Definições do aparelho que foi utilizado para o exame;
- Dose de radiação utilizada no paciente;
- Quantidade de corrente utilizada;
- Tamanho do volume de corte;
- Nome, data de nascimento e sexo, do qual somente a idade e sexo são utilizados para preservar a identidade do paciente;
- Ficha médica com anotações sobre a patologia e laudo médico, quando autorizado.

Recentemente, a incorporação da Inteligência Artificial (IA) na TC tem revolucionado seu uso, trazendo precisão e eficiência ao diagnóstico. A IA pode processar grandes volumes de dados em tempo hábil, identificando padrões que, muitas vezes, passariam despercebidos em uma análise humana tradicional (SANTOS et al., 2019)

Além disso, algoritmos de aprendizado de máquina ajudam a reduzir a dose de radiação necessária para produzir imagens de alta qualidade, tornando o exame mais seguro para o paciente. A IA também permite reconstruções tridimensionais precisas e automação de tarefas repetitivas, o que melhora a experiência e a agilidade para radiologistas e equipes médicas. Assim, a combinação entre tomografia computadorizada e inteligência artificial marca uma nova era na medicina diagnóstica, com potencial para aprimorar o diagnóstico precoce e o tratamento de diversas doenças (CORSO, 2024).

3. INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA), é uma das áreas com grande potencial para a ciência e tecnologia moderna. Definida amplamente como a capacidade de máquinas e sistemas computacionais realizarem tarefas que normalmente requerem inteligência humana, a IA, abrange uma ampla gama de técnicas e aplicações que estão transformando a maneira como os seres humanos vivem e trabalham (OLIVEIRA et al., 2023).

A IA, está revolucionando o diagnóstico por imagem, proporcionando avanços significativos na precisão, eficiência e acessibilidade dos cuidados médicos. Algoritmos de aprendizado de máquina e redes neurais profundas são capazes de analisar grandes volumes de dados de imagem com rapidez e precisão, identificando padrões sutis que podem ser difíceis para os radiologistas humanos detectarem (SANTOS et al., 2019).

A IA pode auxiliar na detecção precoce de doenças, como câncer, ao identificar anomalias em exames de mamografia, tomografia computadorizada (TC) e ressonância magnética (RM). Além disso, algoritmos de IA podem ser treinados para diferenciar entre tipos de lesões e tecidos, proporcionando diagnósticos mais precisos e personalizados (SILVA et al., 2024).

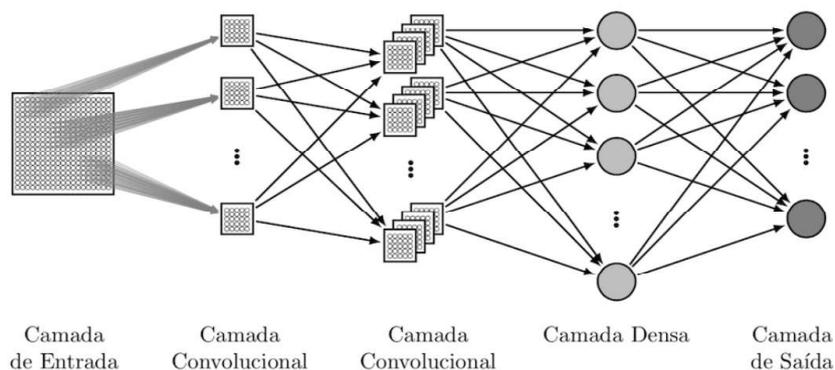
3.1 REDES NEURAI CONVOLUCIONAIS

O conceito de redes neurais convolucionais foi inspirado pelos estudos de *Hubel* e *Wiesel* na década de 1960, que descobriram que os neurônios no córtex visual dos gatos respondiam a regiões específicas de um campo visual. referência levou ao desenvolvimento de algoritmos que poderiam reconhecer padrões visuais de maneira hierárquica (SOUZA, 2023b).

A Figura 10, apresenta uma representação de uma arquitetura de Uma rede neural convolucional (CNN) que é um modelo de aprendizado profundo projetado para processar dados com estrutura de grade, como imagens, extraindo automaticamente características relevantes por meio de camadas convolucionais, *pooling* e totalmente conectadas. CNN, o qual é composto por uma camada de entrada, camadas convolucionais, uma camada densa e uma camada de saída. Essa arquitetura é fundamental para a compreensão dos processos de aprendizado em redes neurais, destacando a organização e a interconexão das diferentes camadas que contribuem para a capacidade de processamento de informações complexas (SOUZA, 2023b).

A estrutura de uma arquitetura de rede neural convolucional (CNN) são com-

Figura 10 – Representação de uma arquitetura CNN.



Fonte:Elaborado por (SAKURAI, 2023)

postas por várias camadas de diferentes tipos e cada uma desempenha um papel específico no processamento da informação, dentre elas a estrutura nomeada de camadas que tem um papel específico no recebimento de sinais e na saída de dados, além desse item importante um neurônio artificial pode possuir também função de ativação e filtros:

- Camadas de Entrada: É responsável por aceitar os dados de entrada na forma de um vetor, matriz ou tensor, dependendo do tipo de dados e da tarefa que a rede está resolvendo. Por exemplo, em uma rede que processa imagens, os dados de entrada podem ser uma matriz 2D ou 3D representando a imagem (largura, altura e, possivelmente, canais de cor).
- A camada convolucional: É uma das componentes principais das redes neurais convolucionais (CNNs). Ela é responsável pela extração de características dos dados de entrada, especialmente imagens, através de operações de convolução. A camada convolucional aplica filtros (ou *kernels*) aos dados de entrada para criar mapas de características, que capturam informações locais e padrões da imagem, como bordas, texturas e formas.
- Camadas de Ativação: que ocorre logo após a camada convolucional, faz as funções de ativação, como *ReLU* (*Rectified Linear Unit*), são aplicadas para introduzir não-linearidade no modelo, permitindo que ele aprenda representações mais complexas, também chamadas de camada convolucional.
- Função de Ativação: Após a operação de convolução, uma função de ativação (como *ReLU*) é aplicada ao mapa de características para introduzir não-linearidade, permitindo que a rede aprenda representações mais complexas.

- **Camadas Completamente Conectadas:** No final da rede, camadas completamente conectadas (ou densas) são usadas para tomar decisões finais com base nas características extraídas. Cada neurônio em uma camada totalmente conectada está ligado a todos os neurônios na camada anterior.
- **Camada de Saída:** Em uma rede CNN é a última camada da rede, responsável por produzir a saída final do modelo. A função principal da camada de saída é mapear as características extraídas e processadas pelas camadas anteriores (camadas convolucionais, de *pooling* e totalmente conectadas) para um formato que corresponda ao problema específico que a rede está tentando resolver. A estrutura e a função da camada de saída variam dependendo do tipo de tarefa de aprendizado que a CNN está abordando (DOMINGUES et al., 2023).

Essa estrutura hierárquica é fundamental para o funcionamento das redes neurais, possibilitando a realização de tarefas complexas, como reconhecimento de padrões e tomada de decisões, em uma variedade de aplicações, desde visão computacional até processamento de linguagem natural.

3.1.1 Filtros

Um filtro é uma pequena matriz de pesos que desliza sobre a entrada (imagem) e realiza uma operação de convolução. O tamanho do filtro é geralmente menor que a dimensão da entrada (por exemplo, 3x3, 5x5).

Cada filtro é treinado para detectar diferentes características. Em uma camada convolucional, pode haver múltiplos filtros, e cada um produz um mapa de características diferente. Operação de Convolução envolve o deslizamento do filtro sobre a entrada, calculando a soma ponderada dos valores da entrada e dos pesos do filtro. O resultado de cada operação de convolução é um valor no mapa de características correspondente. Esse processo é repetido para toda a imagem, gerando um mapa de características completo, dentre os filtros existentes podem ser citados (MESQUITA; OUTROS, 2023).

Filtro Sobel: Utilizado para detecção de bordas, calcula a derivada da intensidade da imagem em duas direções (horizontal e vertical). Ele utiliza máscaras convolucionais:

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (1)$$

O gradiente resultante é dado por:

$$G = \sqrt{G_x^2 + G_y^2} \quad (2)$$

Método de Otsu: Técnica de segmentação binária que encontra automaticamente um limiar T para separar os níveis de cinza da imagem, minimizando a variância intraclasse. O limiar é determinado como:

$$\sigma_B^2(T) = \omega_1(T)\omega_2(T)(\mu_1(T) - \mu_2(T))^2 \quad (3)$$

Onde ω_1 e ω_2 são as probabilidades das classes, e μ_1 e μ_2 são as médias das intensidades.

Filtro Laplaciano: Usado para realçar bordas, baseado na segunda derivada da intensidade da imagem. A máscara comum é:

$$L = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (4)$$

Aplicando a convolução, ele destaca regiões de alta variação de intensidade.

Filtro Gaussiano: Um filtro passa-baixa que suaviza a imagem, reduzindo ruído. A máscara é baseada na função gaussiana:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5)$$

Onde σ controla o grau de suavização.

Filtro de Média: Usado para suavização, substitui cada pixel pelo valor médio de seus vizinhos. Para uma máscara de tamanho $n \times n$:

$$M = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n I(i, j) \quad (6)$$

Os filtros utilizados nas camadas das redes neurais artificiais, especialmente nas redes neurais convolucionais (CNNs), desempenham um papel crucial na extração de características específicas das imagens ou dados de entrada (FILHO; NETO, 1999)

Esses filtros são responsáveis por identificar padrões essenciais, como bordas, texturas e formas, nas camadas iniciais, e por detectar estruturas mais complexas nas camadas mais profundas. Ao aplicarem convoluções sobre os dados, os filtros permitem que a rede "aprenda" automaticamente quais características são mais relevantes para a tarefa em questão, seja ela classificação de imagens, detecção de objetos ou reconhecimento de padrões. Cada filtro ajusta seus parâmetros durante o treinamento, aprimorando sua capacidade de identificar as características que melhor representam o conjunto de dados. Em resumo, os filtros são fundamentais para a capacidade das redes neurais de generalizar e reconhecer padrões com precisão, sendo um dos elementos-chave que tornam o aprendizado profundo tão eficaz e versátil em aplicações práticas (OLIVEIRA et al., 2024).

3.2 DESCRITORES *HARALICK* E REDE NEURAL *PERCEPTRON* MULTICAMADAS

As Redes Neurais Artificiais (RNAs), podem ser aplicadas em várias áreas do conhecimento. São sistemas paralelos formados pela interconexão de unidades de processamento simples, denominadas neurônios. As RNAs, utilizando um conjunto de exemplos, são capazes de generalizar, o conhecimento assimilado, para um conjunto de dados desconhecido. É uma técnica de modelagem que pode resolver muitos problemas complexos de imagem, som, e de qualquer outro segmento (OLIVEIRA; RUSTICK; SANTOS, 2023)

Os descritores de Haralick são baseados na matriz de coocorrência de níveis de cinza (GLCM, do inglês *Gray Level Co-occurrence Matrix*), que descreve como os pares de pixels com valores específicos de intensidade ocorrem em uma determinada relação espacial na imagem. A partir dessa matriz, são calculados 14 descritores estatísticos que quantificam propriedades texturais como uniformidade, contraste e entropia (PRADO, 2018). Os principais descritores incluem:

- **Energia:** Mede a uniformidade da textura. Valores altos indicam padrões regulares e repetitivos:

$$\text{Energia} = \sum_{i=1}^N \sum_{j=1}^N P(i, j)^2 \quad (7)$$

- **Contraste:** Mede a variação de intensidade local na imagem:

$$\text{Contraste} = \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 P(i, j) \quad (8)$$

- **Homogeneidade:** Avalia a proximidade dos elementos da GLCM à diagonal principal:

$$\text{Homogeneidade} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + |i - j|} \quad (9)$$

- **Entropia:** Mede o grau de desordem ou aleatoriedade da textura:

$$\text{Entropia} = - \sum_{i=1}^N \sum_{j=1}^N P(i, j) \log P(i, j) \quad (10)$$

- **Correlação:** Avalia a relação linear entre os pixels:

$$\text{Correlação} = \sum_{i=1}^N \sum_{j=1}^N \frac{(i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j} \quad (11)$$

1. **Construção da GLCM:** A imagem é analisada considerando pares de pixels em diferentes direções (ex.: 0°, 45°, 90° e 135°) e distâncias. Cada par contribui para a matriz de coocorrência.

2. **Normalização:** Os valores da GLCM são normalizados para que a soma total seja igual a 1:

$$P(i, j) = \frac{C(i, j)}{\sum_{i=1}^N \sum_{j=1}^N C(i, j)} \quad (12)$$

3. **Cálculo dos Descritores:** As equações acima são aplicadas à GLCM normalizada para extrair os descritores texturais.

Os descritores de Haralick são ferramentas muito úteis para análise de texturas em imagens, fornecendo informações quantitativas sobre padrões locais e globais. Combinados com filtros de pré-processamento, como os descritos anteriormente, permitem uma compreensão detalhada de imagens em aplicações como segmentação, classificação e reconhecimento de padrões (OLIVEIRA, 2010).

3.2.1 Perceptron Multicamadas MLP

A MLP é uma rede neural comumente usada baseada em aprendizado supervisionado, na qual as informações fluem em uma direção e não possuem *loops*. O objetivo principal é encontrar a função otimizada que mapeia a entrada para a saída desejada e aprender o valor de polarização otimizado para ela. O valor de polarização geralmente se refere ao termo de bias (viés) que é adicionado à soma ponderada das entradas antes de aplicar a função de ativação. Esse termo ajuda a deslocar a função de ativação, permitindo que a rede modele melhor os dados, mesmo quando todas as entradas são zero (COSSA, 2023).

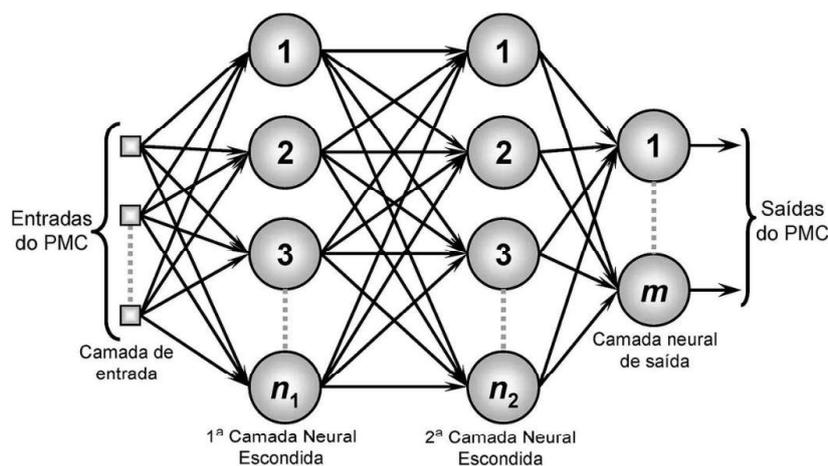
O aprendizado ocorre no MLP usando um algoritmo de retro-propagação, ajustando os pesos da conexão quando há um desvio entre a saída esperada e a real. Suas principais aplicações são para resolver problemas de otimização em finanças, transporte, patrimônio e energia. Ele faz isso com a passagem para frente, Os dados de entrada são propagados pela rede para calcular a saída prevista, e o cálculo do erro é feito calculado usando uma função de custo (ex.: erro quadrático médio). Depois é feito a passagem para trás, O erro é propagado de volta pela rede, camada por camada, usando a regra da cadeia para calcular os gradientes dos pesos e biases (BISI; NETO; BONINI, 2015).

Por possui aprendizado adaptativo, pode aprender a executar tarefas a partir dos dados fornecidos para treinamento e experiência inicial, minimiza a função de perda. É um programa estocástico, que é um tipo de programa que usa processos aleatórios ou probabilísticos para tomar decisões ou gerar resultados, em vez de seguir

uma sequência determinística fixa. Isso permite variação e imprevisibilidade em seus comportamentos ou *outputs* (BARIONI et al., 2007).

A Figura 11 é um exemplo dessa rede que pode ter desde 10 camadas a 128 ou mais, dependendo sempre da necessidade do programa e da capacidade computacional.

Figura 11 – Representação de uma arquitetura MLP.



Fonte: (Medium, 2023)

3.2.2 Descritores *Haralick*

Os descritores de *Haralick* são compostos por 14 medidas matemáticas cujo objetivo é realizar o cálculo de textura da imagem. Essas medidas utilizam a matriz de co-ocorrência, que é formada pela distribuição de *pixels* determinada pela textura da imagem. A matriz é formada por elementos que relacionam a frequência que ocorre em um determinado tom de cinza, X , em relação a outro Y , que são separados por uma distância representada pela letra (d) refere-se ao número de *pixels* entre os pares de *pixels* considerados na matriz de coocorrência de níveis de cinza (GLCM - *Gray-Level Co-occurrence Matrix*). Esse parâmetro é usado para capturar as texturas da imagem e afeta como as relações espaciais entre os *pixels* que são interpretadas, nos ângulos de 0° , 45° , 90° e 315° (SILVA et al., 2022).

Assim, a escolha da distância pode influenciar os descritores finais (como contraste, homogeneidade, energia, etc.), e a análise da textura precisa, muitas vezes, testar várias distâncias para encontrar a mais representativa para a aplicação (TENGUAM, 2023).

Logo, os descritores de *Haralick* são caracterizados por: Segundo Momento Angular, Contraste Variância, Homogeneidade, Soma das Médias, Soma das Variâncias,

Soma das Entropias, Entropia, Variância da Diferença, Entropia da Diferença, Energia, Probabilidade Máxima e Diferenças de Ordem K.

Seja $P(i, j)$ o elemento normalizado da GLCM, que representa a probabilidade de coocorrência entre níveis de cinza i e j . As 14 medidas são definidas como:

1. **Energia (Uniformidade ou Angular Second Moment):** Mede a uniformidade da distribuição:

$$\text{Energia} = \sum_{i=1}^N \sum_{j=1}^N P(i, j)^2 \quad (13)$$

2. **Entropia:** Mede a desordem da textura:

$$\text{Entropia} = - \sum_{i=1}^N \sum_{j=1}^N P(i, j) \log P(i, j) \quad (14)$$

3. **Contraste:** Mede a variação de intensidade local:

$$\text{Contraste} = \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 P(i, j) \quad (15)$$

4. **Correlação:** Avalia a relação linear entre os pixels:

$$\text{Correlação} = \frac{\sum_{i=1}^N \sum_{j=1}^N (i - \mu_i)(j - \mu_j) P(i, j)}{\sigma_i \sigma_j} \quad (16)$$

onde μ_i, μ_j são as médias e σ_i, σ_j os desvios padrão.

5. **Homogeneidade (Inverse Difference Moment):** Mede a proximidade dos valores à diagonal principal:

$$\text{Homogeneidade} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + |i - j|} \quad (17)$$

6. **Variância:** Mede a dispersão dos valores em torno da média:

$$\text{Variância} = \sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 P(i, j) \quad (18)$$

7. **Momento de Diferença de Inversão Normalizada (IDN):**

$$\text{IDN} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + \frac{(i-j)^2}{N^2}} \quad (19)$$

8. Sum Average (Média das Somas):

$$\text{Sum Average} = \sum_{i=2}^{2N} i \cdot P_{\text{sum}}(i) \quad (20)$$

onde $P_{\text{sum}}(i)$ é a soma dos elementos ao longo de $i + j = k$.

9. Sum Entropy (Entropia da Soma):

$$\text{Sum Entropy} = - \sum_{i=2}^{2N} P_{\text{sum}}(i) \log P_{\text{sum}}(i) \quad (21)$$

10. Sum Variance (Variância da Soma):

$$\text{Sum Variance} = \sum_{i=2}^{2N} (i - \text{Sum Average})^2 P_{\text{sum}}(i) \quad (22)$$

11. Difference Variance (Variância da Diferença):

$$\text{Difference Variance} = \sum_{i=0}^{N-1} (i - \mu_d)^2 P_{\text{diff}}(i) \quad (23)$$

onde μ_d é a média de $P_{\text{diff}}(i)$.

12. Difference Entropy (Entropia da Diferença):

$$\text{Difference Entropy} = - \sum_{i=0}^{N-1} P_{\text{diff}}(i) \log P_{\text{diff}}(i) \quad (24)$$

13. Information Measure of Correlation 1:

$$\text{IMC1} = \frac{H_{XY} - H_{XY1}}{\max(H_X, H_Y)} \quad (25)$$

onde H_{XY} é a entropia conjunta, e H_{XY1} é a entropia condicional.

14. Information Measure of Correlation 2:

$$\text{IMC2} = \sqrt{1 - e^{-2(H_{XY2} - H_{XY})}} \quad (26)$$

Onde H_{XY2} é uma medida de entropia condicional alternativa (BARBOSA, 2009).

3.3 REDE CNN XCEPTION

A rede CNN *Xception* é uma rede neural profunda que em vez de utilizar convoluções padrão, ela emprega convoluções separáveis em profundidade, que dividem a operação de convolução em duas etapas: uma convolução de 1x1 e uma convolução de 3x3. Isso reduz a complexidade computacional e melhora a eficiência do modelo. A arquitetura *Xception* é conhecida por alcançar alta precisão em tarefas de visão computacional, como classificação de imagens. Ela é uma evolução da arquitetura *Inception*, oferecendo melhor desempenho com menor custo computacional (CHOLLET, 2017).

A *Xception* é especialmente eficaz em tarefas de visão computacional, incluindo o trabalho com imagens DICOM, devido às seguintes características:

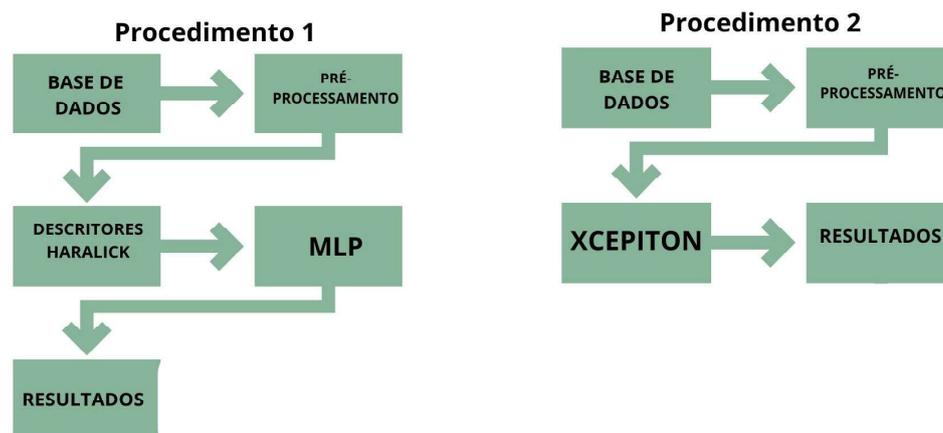
- **Convoluções Separáveis em Profundidade:** A *Xception* utiliza convoluções separáveis em profundidade, que permitem a extração de características mais detalhadas com menor custo computacional. Isso é útil para imagens DICOM, que frequentemente contêm detalhes sutis e complexos.
- **Camadas de Convolução Profunda:** A arquitetura *Xception* é profunda e possui muitas camadas, o que ajuda a capturar e aprender características complexas e hierárquicas das imagens. Isso é essencial para a análise médica, onde as estruturas e padrões podem ser muito complexos.
- **Eficiência Computacional:** A utilização de convoluções separáveis melhora a eficiência computacional sem sacrificar a precisão, o que é benéfico ao lidar com grandes volumes de dados médicos e imagens de alta resolução.
- **Transferência de Aprendizado:** Modelos pré-treinados da *Xception* podem ser adaptados para tarefas específicas usando *fine-tuning*, o que pode ser útil em contextos médicos para identificar e classificar diferentes patologias em imagens DICOM.
- **Desempenho em Classificação:** A *Xception* tem mostrado desempenho superior em tarefas de classificação de imagens, o que pode ser diretamente aplicado para diagnósticos e análises em imagens médicas (SOUZA, 2023a).

Esses fatores combinados fazem da *Xception* uma escolha sólida para aplicações que envolvem imagens DICOM, proporcionando uma análise detalhada e eficiente.

4. METODOLOGIA

Descreve-se aqui a metodologia geral deste trabalho e as técnicas utilizadas, resumido em um esquema na Figura 11. O fluxograma da pesquisa se inicia com a base de dados, logo após o pré-processamento, e então as redes que foram utilizadas, e por fim a análise de dados. Posteriormente será descrito o detalhamento em cada tópico ilustrado.

Figura 12 – Fluxograma da metodologia.



4.1 BASE DE DADOS

As bases de dados, utilizadas nesse trabalho foram denominadas “base1” e “base2” e as bases contemplam imagens de tomografia computadorizada de crânio, padrão DICOM, com dimensão de 512×512 pixels.

A “base1” foi obtida do trabalho de Aguiar (2017), disponibilizada pelo Núcleo de Estudos e Pesquisa em Imagenologia (NEPI), da Universidade Federal da Paraíba (UFPB). Essa base abrange exames de 419 pacientes, com espaçamento médio de cada fatia de imagem de 8mm, desses existem 36 pacientes com acidente vascular cerebral isquêmico e 53 pacientes considerados normais.

A “base2”, por sua vez, possui 500 pacientes com *slices* com espessura de fatia de 5mm e foi obtida do trabalho de Gautam e Raman (2021), que é pública. Essa base contém mais de 15 mil imagens, porém, nem todas pertencem a pacientes com AVC ou sem alterações neurológicas. Há também registros de pacientes com hemotórax, fraturas, leucariose, tumores e infecções. Para garantir a relevância dos dados, foi realizada uma filtragem criteriosa, onde foram excluídos pacientes que apresentaram hipodensidades sugestiva de hematoma subdural crônico, pacientes com lesão hiperdensa de contornos bem definidos, que são características de outras anormalidades, indivíduos em que foram notados desvio da linha média, o que sugere

o caráter expansivo não característico de isquemia cerebral.

A exclusão desses pacientes diminuiu consideravelmente o número de pacientes, resultando em 106 pacientes aptos para esse estudo, sendo 53 normais e 53 com acidente vascular cerebral isquêmico.

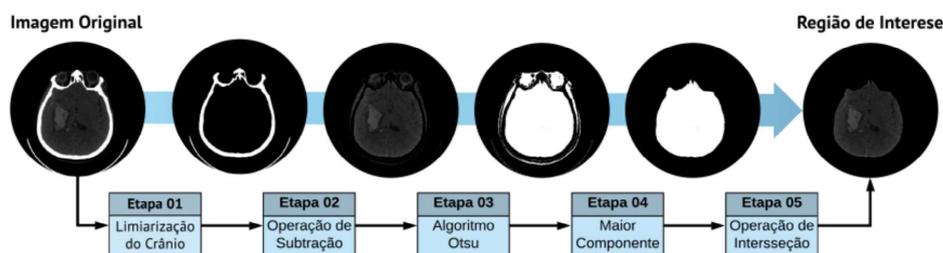
Realizou-se também um novo mapeamento mapeadas dos exames da base1, uma vez que existiam pacientes inconclusivos que foram reanalisado e assim foram adicionados mais 11 pacientes que estavam com hipodensidade, que é área de baixa densidade tecidual (mais escura), indicando edema citotóxico, também conhecido como edema cerebral celular, é um tipo de inchaço do cérebro que ocorre quando as células neuronais retêm líquido ou perda de tecido cerebral, aumentando assim a quantidade de exames com AVCi.

Somando as duas bases foram obtidas, 39 imagens de AVCi agudo, 32 imagens de AVCi subagudo e 55 imagens de AVCi crônico, somando 173 imagens, levando em consideração somente a parte do cérebro que pode ser atingida por AVCi. Para pacientes considerados normais, foram selecionados a mesma quantidade de imagens. Os laudos de cada paciente foram cuidadosamente revisados e confirmados pelo médico especialista Dr. André Moreira Santos Júnior (CRM-17.756).

4.2 PRÉ-PROCESSAMENTO

Após a separação e seleção das imagens a serem utilizadas, as imagens aptas foram submetidas a um pré-processamento comum. O pré-processamento consiste na exclusão dos elementos externos ao crânio, como observado na Figura 13. Na exclusão foi realizado um janelamento de 0 a 150 UH, como observado na Equação 1, visto que os tecidos cerebrais normais e com possíveis AVCi encontram-se dentro dessa faixa.

Figura 13 – Exclusão de elementos externos.



Fonte: Elaborado por (SARMENTO, 2021)

$$p(x, y) = \begin{cases} 0, & \text{if } I(x, y) < 0, \\ I(x, y) & \text{if } 0 \leq I(x, y) \leq 150, \\ 255, & \text{if } I(x, y) > 150. \end{cases} \quad (27)$$

A equação apresentada é definida por partes, onde o valor de $p(x, y)$ depende das condições associadas à função $I(x, y)$. Abaixo está a interpretação de cada parte:

- $p(x, y) = 0$: Isso ocorre quando $I(x, y) < 0$. Ou seja, quando os valores da função $I(x, y)$ são negativos, $p(x, y)$ é fixado como zero;
- $p(x, y) = I(x, y)$: Isso ocorre quando $0 \leq I(x, y) \leq 150$. Neste intervalo, $p(x, y)$ assume o mesmo valor da função $I(x, y)$;
- $p(x, y) = 255$: Isso ocorre quando $I(x, y) > 150$. Ou seja, quando os valores da função $I(x, y)$ excedem 150, $p(x, y)$ é fixado como 255.

Em resumo, $p(x, y)$ é uma transformação de intensidade baseada em limiares da função $I(x, y)$. Isso é aplicado, geralmente, no contexto de processamento de imagens, como na segmentação ou ajuste de brilho.

Na primeira etapa realiza-se a segmentação primária do crânio com o objetivo de definir os limites anatômicos da área de interesse. Esse procedimento é crucial para restringir o processamento subsequente exclusivamente à região craniana, minimizando interferências de áreas externas.

Em seguida, na etapa 2, aplica-se uma operação aritmética de subtração, visando a remoção de artefatos ou elementos indesejados fora da região de interesse. Essa etapa elimina dados redundantes que possam interferir no processo de análise. Logo em seguida, na etapa 3, foi realizado a limiarização global pelo método de *Otsu*, que determina a separação de forma automática, isso ocasiona a separação entre as regiões de interesse, ou seja separa o interior do crânio, e o fundo ou qualquer outro elemento externo, com base na maximização da variância de interclasse.

A extração do maior componente é realizado na etapa 4, com base no resultado da limiarização, seleciona-se o maior componente conectado da imagem. Esta etapa permite isolar a estrutura mais significativa (geralmente o crânio ou o cérebro), descartando objetos menores que não pertencem à região de interesse. Por fim, na última etapa, a 5, é feito a operação de interseção entre a segmentação previamente definida e os resultados das etapas anteriores. Este procedimento garante a preservação exclusiva da área relevante, excluindo quaisquer informações redundantes ou ruídos.

O resultado final, apresentado à direita, corresponde à região de interesse isolada, geralmente utilizada para diagnósticos médicos ou análises específicas, garantindo maior precisão no processamento e interpretação da imagem (SOBEL, 1968).

Para obter a marcação da borda interna e externa da calota craniana. Identificada a calota preenchida, faz-se a exclusão da mesma com uma subtração entre a imagem original e a imagem com a calota craniana em destaque, devido a sua não relevância para esse estudo a calota foi retirada de todas as imagens (Figura 13).

Também, foi aplicado um janelamento, pois para trabalhar com as funções do Python de processamento de imagens e as imagens DICOM é necessário diminuir o número de *bits* de 10 para 8. Uma vez que as funções são todas para 8 bits.

Ainda pode haver presença de algumas regiões externas ao crânio, que podem impactar negativamente na análise de densidades radiológicas. Logo, é importante que apenas a região interna ao crânio seja analisada, a área óssea craniana não é objeto de estudo desse projeto por esse motivo, mais uma vez é aplicado algoritmo *Otsu* seguido pela seleção do maior componente da nova imagem binarizada. A região de maior área é justamente a região interna do cérebro, removendo assim a calota craniana.

Por fim, é realizada a última alteração que é uma operação morfológica de intersecção entre a imagem gerada e a imagem original, obtendo-se apenas a região interna da caixa craniana sem a presença de qualquer ruído (SARMENTO, 2021).

4.3 PROCEDIMENTO COM DESCRITORES *HARALICK* E REDE MLP

O procedimento com descritores Haralick e rede MLP (*Multi-Layer Perceptron*) é uma técnica usada para análise e classificação de imagens. Os descritores Haralick, extraídos da matriz de coocorrência de níveis de cinza (GLCM), capturam informações texturais de uma imagem, como contraste, correlação e homogeneidade. Já a rede MLP é um tipo de rede neural artificial que, ao receber os descritores como entrada, pode aprender padrões complexos e realizar classificações, sendo amplamente utilizada em reconhecimento de padrões e processamento de imagens.

A etapa pré-processamento consiste em separar os slices, de cada paciente foram retirados de 6 a 10 slices, onde foi usado 70% dos slices para treinamento e 30% para validação. E a inclusão dos metadados, idade e sexo que segundo a literatura (LUIZ; EIDT; OLIVEIRA, 2021), são fatores de riscos para a ocorrência do AVC e portanto parâmetros que podem influenciar nas métricas da rede MLP.

A etapa seguinte é aplicar os descritores de Haralick em cada um dos slices selecionados, retornando assim os parâmetros de saída que são: Segundo Momento

Angular, Contraste, Variância, Soma das Entropias, Entropia, Variância da Diferença, Entropia da Diferença, Energia, Probabilidade Máxima e Diferenças de Ordem K (NOGUEIRA et al., 2023).

Na próxima etapa foi realizado a normalização da idade dos paciente diminuindo a discrepância entre os valores e também a categorização do sexo de cada paciente, transformando a em uma variável numérica para utilizá-la no processo de aprendizagem de máquina.

Logo em seguida foi inserida na rede *MLP* as os parametros de saída do Haralick e idade e sexo, para que a rede possa realizar a classificação, por meio do treinamento supervisionado com retro propagação de erros.

4.4 PROCEDIMENTO COM A REDE CNN XCEPITON

Primeiramente, foi realizada a unificação das bases de dados 1 e 2, onde cada paciente foi reavaliado de forma individual e retirado alguns pacientes que apresentavam uma visualização da imagem comprometida ou outras patologias. Assim, como também pacientes com laudos inconclusivos, indivíduos que apresentavam mais de uma patologia no mesmo slices, também foi removido.

Depois, foram selecionadas as classificações de fases de AVCi. Os AVCis que representavam duas ou mais fases na mesma fatia de imagem foi retirado, cada fase foi separada por pasta. Para cada pasta, uma nova avaliação do médico foi realizada para consolidar a fase de isquemia ali representada.

Para inserir na rede foi escolhido a mesma quantidade de imagens com paciente normais e AVCi, para que a rede permanecesse balanceada. Foram escolhidos 53 pacientes com a patologia AVCi e 53 pacientes sem AVCi, com algumas alterações de variação anatômica, porém considerados normais.

Essas variações anatômicas em maioria se dá por conta da idade avançada dos pacientes, os cérebros idosos são diferentes dos cérebros jovens devido a uma combinação de mudanças estruturais, funcionais e bioquímicas que ocorrem naturalmente com o envelhecimento. Embora essas alterações sejam parte do processo normal de envelhecimento, elas podem influenciar as capacidades cognitivas, a memória, e até mesmo a personalidade de uma pessoa.

Na imagem de TC é capaz de visualizar as alterações estruturais, e as patológicas como no caso da leucariose, que é muito presente em cérebros acima de 50 anos (LEE; WONG et al., 2023).

Posteriormente, foi realizado o mesmo pré-processamento da rede MLP, seguindo as mesmas etapas, ou seja, foram excluídos toda a parte óssea da calota

craniana e a escala de HU, manteve-se a mesma de 0 a 150 UH, de forma padrão foram utilizadas 70% das imagens treinamento e 30% foram utilizadas para validação. Então, foram inseridos os dados na rede e foi obtido o resultado final que será descrito no próximo capítulo.

5. ANÁLISE DE RESULTADOS

Foram analisados primeiramente os Descritores *Haralick* e rede MLP e posteriormente a rede *Xception*. Nesse trabalho, foram utilizadas as métricas de precisão, sensibilidade e F1-Score que são fundamentais para avaliar o desempenho de modelos de classificação, especialmente quando se trata de problemas de classificação binária.

Antes de entender essas métricas, é importante compreender a matriz de confusão, a matriz de confusão, permite uma análise completa do modelo, mostrando não apenas a taxa de acertos, mas onde o modelo está errando. Isso é especialmente importante em aplicações críticas, como diagnósticos médicos, onde o impacto de um falso negativo ou falso positivo pode ter grandes consequências. Ela é composta por TP (*True Positives*), FP (*False Positives*), TN (*True Negatives*) e FN (*False Negatives*) (MACHADO et al., 2024) no qual:

- TP (*True Positives*): Verdadeiros Positivos, ou seja, casos onde o modelo previu "positivo" corretamente.
- FP (*False Positives*): Falsos Positivos, ou seja, casos onde o modelo previu "positivo", mas na verdade era "negativo".
- TN (*True Negatives*): Verdadeiros Negativos, ou seja, casos onde o modelo previu "negativo" corretamente.
- FN (*False Negatives*): Falsos Negativos, ou seja, casos onde o modelo previu "negativo", mas na verdade era "positivo".

A Precisão (Equação 28), indica a proporção de predições positivas que realmente são positivas. Ela responde à pergunta: Dentre as amostras classificadas como positivas, quantas realmente são positivas.

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (28)$$

A Sensibilidade (Equação 29), também conhecida como taxa de Verdadeiros Positivos, mede a proporção de positivos reais que foram identificados corretamente pelo modelo. Ela responde à pergunta: Dentre todas as amostras que são realmente positivas, quantas foram classificadas corretamente.

$$\text{Sensibilidade} = \frac{TP}{TP + FN} \quad (29)$$

O F1-Score (Equação 30) é a média harmônica entre a Precisão e a Sensibilidade. Ele é útil em cenários em que precisa de um equilíbrio entre Precisão e Sensibilidade.

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (30)$$

A precisão é útil quando o custo de um falso positivo é alto. Já a sensibilidade é importante quando o custo de um falso negativo é alto. O F1-Score é preferível quando há um equilíbrio necessário entre Precisão e Sensibilidade, especialmente em conjuntos de dados desbalanceados. Essas métricas são frequentemente utilizadas em conjunto para ter uma visão mais completa do desempenho do modelo de classificação (BIOINFO, 2024).

5.1 ANÁLISE COM DESCRITORES *HARALICK* E REDE MLP

Os resultados da identificação do AVCi usando os descritores de *Haralick* e MLP, foram feitos através de uma análise incluindo metadados, sexo e idade. Os resultados levam em conta a acurácia que mede a proporção de previsões corretas (positivas e negativas) em relação ao total de exemplos avaliados. A precisão mede a proporção de verdadeiros positivos em relação ao total de exemplos classificados como positivos. Também conhecida como *recall* ou taxa de verdadeiros positivos, a sensibilidade mede a proporção de verdadeiros positivos identificados em relação ao total de exemplos que realmente são positivos. O F1-Score é a média harmônica entre a precisão e a sensibilidade.

Nas Tabelas 2 e 3 são apresentados os resultados obtidos em função da distância usada para obter a matriz de coocorrência, na análise de vizinhança de pixel. Na Tabela 2 são apresentados, os resultados utilizando sexo e idade, e na Tabela 3 sem eles.

Tabela 2 – MLP e *Haralick* com metadados.

DISTÂNCIA	ACC.	PREC.	SEN.	F1-SCORE
10	0,6834	0,6963	0,7054	0,7008
8	0,7342	0,7283	0,7486	7,7383
6	0,6256	0,6246	0,6274	0,6259
5	0,6675	0,6659	0,6681	0,6669
2	0,6335	0,6157	0,6442	0,6296

Fonte: Elaborado pelo Autor.

A partir dos resultados das Tabelas 1 e 2 é possível observar que a distância 8

obteve o melhor resultado, além disso é observado a melhora ao incluir os metadados de sexo e idade na rede neural. Essa análise pode ser observada analisando a Acurácia, Precisão, Sensibilidade e F1-score.

Tabela 3 – MLP e Haralick sem metadados.

DISTÂNCIA	ACC.	PREC.	SEN.	F1-SCORE
10	0,5731	0,5843	0,5554	0,5694
8	0,6431	0,6325	0,6572	0,6446
6	0,6198	0,6243	0,6174	0,6208
5	0,6184	0,6265	0,6142	0,6202
2	0,5784	0,5894	0,5676	0,5782

Fonte: Elaborado pelo Autor.

Comparando os resultados com os resultados apresentados em Aguiar (2017), percebe-se que houve uma pequena melhora na acurácia. Nesse trabalho foram obtidos os valores de 73,42% para acurácia e 74,86% para sensibilidade, enquanto em Aguiar (2017), foram observados e 72% para acurácia e 88% sensibilidade respectivamente, mostrando um aumento da sensibilidade.

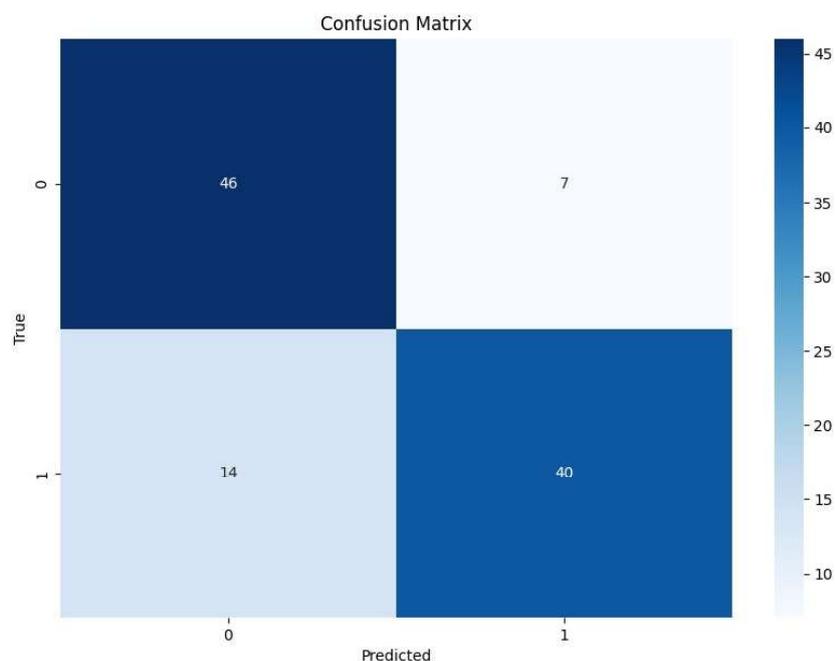
Um fator importante que contribuiu para esse resultado foi o janelamento feito no pré-processamento, na radiologia e Escala Hounsfiel é de vital importância, pois quantifica a densidade dos tecidos em exames de tomografia computadorizada (TC), permitindo a diferenciação precisa entre estruturas como ossos, músculos e líquidos. Essa precisão é crucial para diagnósticos e planos de tratamento eficazes. Logo, o janelamento mais adequado para a identificação de AVCi é de 0 UH a 150 UH.

5.2 ANÁLISE DE RESULTADOS COM A REDE XCEPTION

A rede *Xception* utilizou um total de 346 imagens, onde 70% foi para treino, com 239 imagens e 30% validação, com 107 imagens. No qual o objetivo era classificar isquemia ou não. Na Tabela 3, são apresentados os resultados relativos ao modelo *Xception*, o qual obteve uma acurácia de 80,40%.

Tabela 4 – Métricas de Avaliação do Modelo.

Métrica	Valor
Acurácia	80,40%
Sensibilidade	74,10%
Precisão	85,11%
F-Score	79,21%

Figura 14 – Matriz de Confusão dos resultados da rede *Xception*.

Fonte: Autoria Própria.

A matriz de confusão apresentada na Figura 15 mostra os resultados da classificação de um modelo em duas classes (0 e 1). Cada célula da matriz representa a quantidade de previsões feitas em comparação com os valores reais, permitindo uma análise do desempenho do modelo.

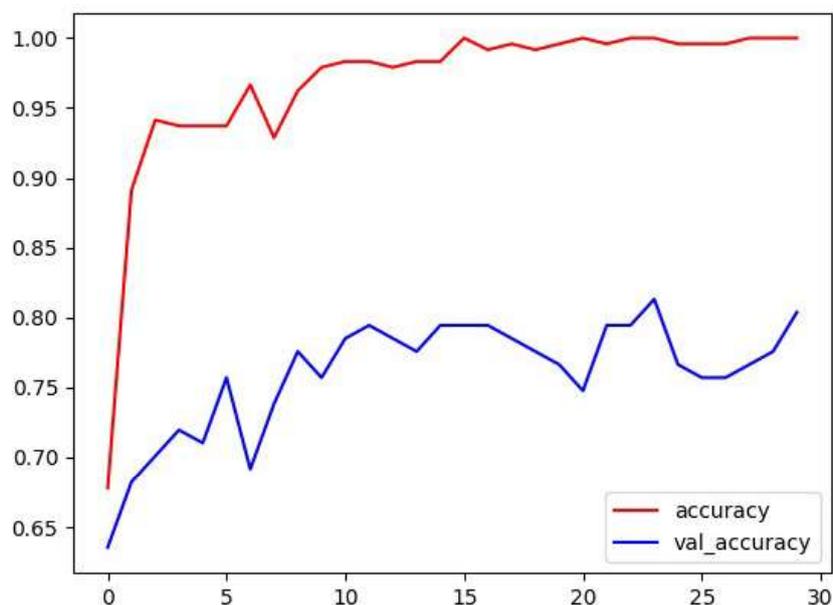
- *True Negatives* (0,0): Na célula superior esquerda (46), o modelo previu corretamente a classe 0 para 46 amostras. *False Positives* (0,1): Na célula superior direita (7), o modelo previu incorretamente a classe 1 para 7 amostras que na verdade eram da classe 0.
- *False Negatives* (1,0): Na célula inferior esquerda (14), o modelo previu incorretamente a classe 0 para 14 amostras que na verdade eram da classe 1.
- *True Positives* (1,1): Na célula inferior direita (40), o modelo previu corretamente a classe 1 para 40 amostras.

A acurácia é a soma dos acertos ($46 + 40 = 86$) em relação ao total de previsões ($46 + 7 + 14 + 40 = 107$) indica a taxa de acurácia do modelo. Erro: O modelo cometeu erros ao classificar 21 amostras (7 FP e 14 FN). Já a sensibilidade (ou taxa de verdadeiros positivos) pode ser calculada para a classe 1, que mostra a capacidade do modelo de identificar corretamente as amostras dessa classe.

A matriz de confusão revela que o modelo erra tanto com falsos positivos quanto com falsos negativos, o que sugere que ajustes podem ser feitos nos parâmetros do

modelo, ou talvez utilizar técnicas de balanceamento de classes, fazendo a separação dos níveis de AVCi, para que assim melhore seus resultados.

Figura 15 – Gráfico de resultados da rede Xception.



Fonte: Autoria Própria.

Na Figura 15 são apresentadas as curvas de acurácia (*accuracy*) e acurácia de validação (*val_accuracy*) ao longo das épocas de treinamento. A linha vermelha representa a acurácia do conjunto de treinamento, enquanto a linha azul representa a acurácia do conjunto de validação.

A acurácia do treinamento aumenta rapidamente nas primeiras épocas, atingindo quase 100% e permanecendo alta, o que indica que o modelo está se ajustando bem aos dados de treinamento. A acurácia de validação também aumenta nas primeiras épocas, mas flutua e se estabiliza em torno de um valor mais baixo, próximo a 80%. Esse comportamento sugere que o modelo está aprendendo a generalizar, mas com algumas dificuldades, possivelmente devido a *overfitting*.

A grande diferença entre a acurácia de treinamento (próxima de 100%) e a acurácia de validação (com de 80%) indica que o modelo pode estar sofrendo de *overfitting*, ou seja, está muito bem ajustado aos dados de treinamento, mas não generaliza tão bem para novos dados (validação). Para que os resultados sejam melhores é necessário uma base de dados ainda maior.

Diante desse resultado, realizou-se uma avaliação geral das inconsistências da rede, a qual revelou que 75% dos erros estavam concentrados nas fases 1 e 2, sendo 50% na fase 1 e 25% na fase 2. Esse padrão já era esperado, uma vez que essas são as fases isquêmicas de mais difícil interpretação, até mesmo para médicos radiologistas experientes. Foi realizado uma avaliação pós-resultado em conjunto com

o médico e feito a classificação de fases baseada nos erros e acertos da rede, onde: Das inconsistências normais, onde os pacientes eram normais e rede classificou como AVCi, 90% eram do sexo masculino maiores de 59 anos. A avaliação médica constatou que os erros apresentados nessa classificação se deu por conta da fisiologia de um cérebro 50+, perde massa cefálica por diversos fatores como, perda de neurônios diminuição da produção de hormônios e neurotransmissores perda de conexões entre neurônios, Acúmulo de proteínas nos neurônios Afinamento da área cortical, Perda de tecido cinza e branco e aumento do volume dos ventrículos.

Embora a perda de massa cefálica após os 50 anos seja maior em mulheres do que em homens, isso pode ter ocorrido pelo tamanho da base de dados. Para pacientes que possuíam AVCi e foram classificados como normais 62,5% das inconsistências foram de pacientes femininos acima dos 48 anos, foi notado pelo médico que a fase com mais erros foi a 1, o padrão dessas inconsistência são a falta de massa cefálica no lobo frontal que acontece de maneira natural e com mais frequência em mulheres. As outras inconsistências foram avaliadas e a possível confusão da rede nas fase 3 e 4 é pela proximidade do AVCi com a área dos ventrículos.

Observou-se, ainda, que o maior percentual de erro de forma geral, ocorreu entre pacientes do sexo feminino, o que pode ser atribuído à fisiologia cerebral feminina, caracterizada por uma maior quantidade de massa cinzenta em comparação ao cérebro masculino. A idade também se revelou ser um fator relevante na taxa de erro, visto que os pacientes com inconsistências tinham, em sua maioria, mais de 69 anos e se encontravam nas fases 1 e 2 da isquemia.

Nas fases 3 e 4, que correspondem a estágios de maior facilidade de interpretação, uma vez que a diferença na densidade tecidual cerebral se torna mais evidente, a taxa de erro para ambas foi de 12,5%.

Em Sarmiento (2021) onde apresenta-se um resultado de quase 90% de acurácia possui uma base de dados por 25 exames não declarados de isquemia ou hemorrágico, o que compromete a reprodutividade da pesquisa, ele ainda conta com 420 imagens em conjunto e não discriminadas, a base de dados que foi utilizada não foi encontrada. Foi feita a tentativa de contato com o mesmo durante um ano e meio, sem sucesso. A reprodução do método proposto por ele não foi possível.

Nos trabalhos de Silva, Carro e Costa (2019), Gao et al. (2020), Merdas (2024), Silva et al. (2022), obtiveram uma média de acurácia de 90%, porém, não há clareza quanto à quantidade de pacientes analisados, nem se o acidente vascular cerebral estudado foi do tipo hemorrágico ou isquêmico. Além disso, não há qualquer indicação de um detalhamento das fases dos AVCs, o que pode gerar uma generalização inadequada no processo de aprendizado da rede, levando-a a interpretar os

dados de forma incorreta.

No estudo de Pilan (2023), foi utilizada uma base de dados da plataforma *Kaggle* contendo 5110 registros, classificados como AVCi, AVCh e sem AVC. Destas foram analisadas 473 imagens, sendo 299 de pacientes com AVC e 173 de pacientes declarados sem AVC. Segundo o autor o desbalanceamento da base de dados contribuiu para a redução dos resultados de acurácia. Entretanto, o autor empregou metadados, como idade, sexo e a presença de doenças associadas, obtendo uma acurácia de 73%. Apesar da acurácia relativamente baixa, este trabalho destacou-se como o mais detalhado e reprodutível da literatura.

5.3 COMPARAÇÃO ENTRE OS RESULTADOS

O desempenho dos modelos foi examinado com base em diferentes abordagens e conjuntos de dados. Inicialmente, utilizou-se a rede *MLP* com descritores de Haralick, considerando variáveis como sexo e idade dos pacientes, além de distâncias para a matriz de coocorrência de *pixels*. Observou-se que a distância de 8 *pixels* apresentou os melhores resultados, com uma acurácia de 73,42% e sensibilidade de 74,86%, melhorando quando metadados foram incluídos.

Em contrapartida, a rede *Xception* superou a *MLP* ao alcançar uma acurácia de 80,40%, sensibilidade de 74,10% e precisão de 85,11%, destacando-se como o modelo mais eficaz para detecção de isquemia. No entanto, houve dificuldades na interpretação das fases iniciais do AVC isquêmico, o que impactou os resultados, principalmente entre pacientes mais idosos e do sexo feminino, devido a fatores fisiológicos como diferenças na massa cinzenta cerebral.

Para aprimorar os resultados, seria benéfico expandir a base de dados com mais pacientes e imagens segmentadas por fase do AVC, além de integrar informações clínicas mais detalhadas.

Além disso, torna-se essencial que estudos futuros tenham acesso aos dados clínicos de cada paciente para aprimorar a base de informações, uma vez que o diagnóstico médico não se baseia apenas em exames de imagem. O laudo médico é resultado da integração de dados clínicos, histórico do paciente e exames complementares, como os de imagem.

6. CONCLUSÃO

Este estudo investigou o desenvolvimento e a aplicação de técnicas avançadas de inteligência artificial para a identificação e classificação do Acidente Vascular Cerebral isquêmico (AVCi) em imagens de tomografia computadorizada. A pesquisa concentrou-se na exploração e implementação de modelos de aprendizado de máquina e redes neurais profundas, que demonstraram eficácia na detecção automática de lesões isquêmicas em imagens médicas, oferecendo um importante suporte ao diagnóstico precoce e, conseqüentemente, auxiliando os profissionais de saúde na tomada de decisões clínicas.

Embora a acurácia deste trabalho tenha sido de 80,40%. Esse projeto foi o relata as fases do AVCi, sendo seu diferencial, quando comparado aos outros trabalhos nos últimos cinco anos, ao longo do trabalho, foi evidenciado que os modelos propostos alcançaram desempenho satisfatório em termos de acurácia na classificação das lesões isquêmicas, comprovando o potencial das abordagens baseadas em inteligência artificial na identificação de padrões complexos e sutis que podem escapar à análise visual tradicional. Além disso, o emprego de algoritmos avançados de pré-processamento de imagem e da *Xception* contribuiu significativamente para a melhoria da robustez e da capacidade de generalização dos modelos, mesmo diante de uma base pequena.

Apesar dos avanços obtidos, algumas limitações foram observadas. A variabilidade nas imagens de tomografia, decorrente de divergências entre os equipamentos utilizados, protocolos de aquisição e características individuais dos pacientes, pode impactar negativamente a performance dos modelos quando aplicados em cenários reais. Ademais, a escassez de conjuntos de dados rotulados, utilizados para o treinamento das redes, representou um desafio significativo, evidenciando a necessidade de colaboração entre instituições de saúde para a construção de bases de dados mais extensas e diversificadas. Outro ponto importante levantado foi a relevância de associar laudos médicos às imagens, de modo a incorporar metadados na rede neural, o que poderia enriquecer a análise e a precisão dos diagnósticos.

Para futuras pesquisas, sugere-se a integração de dados clínicos adicionais, como informações textuais relativas ao histórico médico dos pacientes, a fim de complementar a análise das imagens e aprimorar a acurácia dos diagnósticos. Além disso, seria relevante explorar o uso de técnicas de aprendizado por transferência, utilizando modelos pré-treinados em grandes bases de dados médicos, para melhorar a capacidade de generalização dos modelos propostos. a inclusão da classificação dos diferentes estágios do AVCi no processo de aprendizado da máquina também

se mostra essencial, visando garantir que os modelos sejam capazes de discriminar corretamente as diferentes fases do evento isquêmico.

Por fim, espera-se que este trabalho contribua significativamente para o avanço das tecnologias de diagnóstico assistido por computador na área da neurologia, e futuramente possa oferecer uma ferramenta adicional no enfrentamento do AVCi, que permanece como uma das principais causas de mortalidade e incapacidade no mundo.

7. TRABALHOS PUBLICADOS

Nogueira, B. J. S; da Silva, E. T. A.; Rodrigues, L. W.L; Regis, C. D. M. **Identificação de AVCi utilizando Extração de Características e uma rede MLP em Imagens de CT.** Simpósio Brasileiro de Telecomunicações e Processamento de Sinais, 2023, São José dos Campos - SP.

REFERÊNCIAS

ABRAHÃO, V. P. Anatomia comparada do sistema nervoso central e filogenia da família pseudopimelodidae (ostariophysi: Siluriformes). 2024.

AGUIAR, C. B. D. **Avaliação de Acidente Vascular Cerebral**. Dissertação (Mestrado) — Instituto Federal da Paraíba (IFPB), João Pessoa-PB, 2017.

AL-RAMMAHI, H. M. et al. Root and canal anatomy of mandibular first molars using micro-computed tomography: a systematic review. **National Library of Medicine**, v. 1, 2023.

ALMEIDA, A. N. B. de et al. Fisiopatologia do sangramento cerebral: entendendo o AVC hemorrágico. **CONTRIBUCIONES A LAS CIENCIAS SOCIALES**, v. 17, n. 8, p. e9192–e9192, 2024.

AMARAL, R. S. do; CAIXETA, B. Avanços no uso da tomografia computadorizada (tc) para diagnóstico pediátrico: avaliação de segurança, eficácia e melhores práticas. **Brazilian Journal of Health and Biological Science**, v. 1, n. 1, p. e74–e74, 2024.

American Stroke Foundation. **Stroker**. 2024. Disponível em: <<https://www.stroke.org>>.

BARBOSA, D. P. Avaliação de descritores texturais geoestatísticos e de haralick para o reconhecimento de plantas daninhas. Universidade Federal de Viçosa, 2009.

BARIONI, L. et al. Modelos determinista e estocástico em programas de transferência de embriões em bovinos. **Archivos Latinoamericanos de Produccion Animal**, v. 15, n. 3, p. 107–113, 2007.

BIOINFO. **Métricas de Avaliação em Machine Learning: Acurácia, Sensibilidade, Precisão, Especificidade e F-score**. 2024.

Acessado em: 15-08-2024. Disponível em: <<https://bioinfo.com.br/metricas-de-avaliacao-em-machine-learning-acuracia-sensibilidade-precisao-especificidade-e-f-score>>.

BISI, B. S.; NETO, A. B.; BONINI, C. d. S. B. Redes neurais artificiais: Utilização do algoritmo retropropagação para classificação de grupos em biosistemas, parte 1: Introdução teórica. **Periódico Eletrônico Fórum Ambiental da Alta Paulista**, v. 11, n. 2, 2015.

BOTTEGA, P. et al. Tomografia computadorizada quantitativa da densidade óssea mandibular ao redor de implantes osseointegrados: estudo comparativo dos valores da unidade hounsfield e pixel trabecular. **Brazilian Journal of Development**, v. 9, n. 7, p. 22995–23011, 2023.

BRASIL, M. da S. **AVC**. 2019. Disponível em: <<https://www.saude.gov.br/>>.

BRASIL, M. da S. **DATASUS - Departamento de Informática do SUS**. 2023. Disponível em: <<https://datasus.saude.gov.br/>>.

CABRAL, Y. A. D. et al. Acidente vascular cerebral isquêmico (avci) em jovens: Do diagnóstico ao tratamento. **RICS - Revista Interdisciplinar das Ciências da Saúde**, v. 1, n. 1, p. 1–17, 2024.

- CASTELO-BRANCO, L. A evolução da medicina e integração das novas tecnologias de saúde. **Revista Portuguesa de Farmacoterapia**, v. 10, n. 2-3, p. 30–32, 2018.
- CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. **arXiv preprint arXiv:1610.02357**, 2017.
- CONCEIÇÃO, D. L. Computed tomography in ischemic stroke. **Brazilian Journal of Health Review**, Curitiba, v. 3, n. abril, p. 6329–6333, 2023. ISSN 2595-6825.
- CORSO, R. L. **Aplicação da Inteligência Artificial para Análise Anatômica da Região de Incisivos Centrais Superiores por Meio de Imagens de Tomografia Computadorizada de Feixe Cônico Segundo a Classificação de Kan**. Dissertação (Dissertação de Mestrado) — Universidade de Caxias do Sul, 2024.
- COSSA, G. C. S. Mitigação do efeito das não linearidades em sistemas de comunicações ópticas coerentes digitais com multiplexação de polarização utilizando redes neurais artificiais. Universidade Estadual Paulista (Unesp), 2023.
- CRESPI, L.; NORO, D.; NÓBILE, M. F. Neurodesenvolvimento na primeira infância: aspectos significativos para o atendimento escolar na educação infantil. **Ensino em Re-Vista**, Universidade Federal de Uberlândia, v. 27, n. SPE, p. 1517–1541, 2020.
- DESCATTO, T. **Livro De Tomografia Computadorizada**. [S.l.]: Clube de Autores, 2023.
- DINIZ, J. O. B. et al. Segmentação de coração em tomografias computadorizadas utilizando atlas probabilístico e redes neurais convolucionais. In: **Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)**. [S.l.: s.n.], 2021.
- DOMINGUES, J. G. et al. Desenvolvimento de rede neural convolucional para o diagnóstico radiográfico de osteoartrite dos joelhos no elsa-brasil musculoesquelético. **Radiologia Brasileira**, v. 56, p. 248–254, 2023.
- DURÁN, M.; NAVAS, B. B.; SÁNCHEZ, J. M. F. **Tomografía computarizada maxilofacial en el perro**. [S.l.]: Grupo Asís Biomedica SL, 2024.
- EDUCAÇÃO, M. **Neurônios**. 2023. Acesso em: 21 jul. 2024. Disponível em: <<https://mundoeducacao.uol.com.br/biologia/neuronios.htm>>.
- FARIA, C. M. et al. As funções executivas e o transtorno do espectro autista: Um diálogo neuropsicológico. **BIUS-Boletim Informativo Unimotrisaúde em Sociogerontologia**, v. 45, n. 39, p. 1–11, 2024.
- FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. [S.l.]: Brasport, 1999.
- FLOHR, T. G. **The Evolution of CT Technology: From Conventional to Spectral CT**. [S.l.]: Springer, 2022.
- GAO, Z. et al. Deep learning application in plant stress imaging: a review. **AgriEngineering**, MDPI, v. 2, n. 3, p. 29, 2020.
- GAUTAM, A.; RAMAN, B. Rumo à classificação eficaz de acidente vascular cerebral hemorrágico e isquêmico cerebral usando cnn. **Biomedical Signal Processing and Control**, Elsevier, v. 63, p. 102178, 2021.

GOLDSTEIN, S.; NAGLIERI, J. (Ed.). **Neuropsychological Assessment of Executive Functions**. [S.l.]: Springer, 2023.

GUERREIRO, L. M. **Hiperhomocisteinemia no AVC Isquêmico do Jovem**. Tese (Tese de Doutorado) — Universidade onde a tese foi defendida, 2023.

HSIEH, J. **Computed Tomography: Principles, Design, Artifacts, and Recent Advances**. 4. ed. [S.l.]: SPIE Press, 2022.

LEE, M.; WONG, B. et al. Ct imaging in aging: Insights into structural changes and pathologies. **NeuroRadiology Review**, v. 45, n. 2, p. 123–135, 2023.

LOPES, T. L. D. O. A. et al. Fatores de risco relacionados com a alta taxa de morbimortalidade dos pacientes acometidos por acidente vascular cerebral isquêmico no nordeste brasileiro. **Brazilian Journal of Health Review**, v. 6, n. 6, p. 28951–28965, 2023.

LUIZ, J. M.; EIDT, N.; OLIVEIRA, N. P. D. Campanha de combate ao avc: relato de um projeto de extensão da ufsc no município de araranguá/sc. **Revista Eletrônica de Extensão**, v. 18, n. 39, p. 90–100, August 2021.

MACHADO, D. F. M. G. et al. Avaliação de algoritmos de aprendizado de máquina na previsão de evasão escolar: estudo de caso no ifpa campus altamira. **Cuadernos de Educación y Desarrollo**, v. 16, n. 10, p. e5874–e5874, 2024.

MACKENZIE, A.; LEWIS, E.; LOVELAND, J. Successes and challenges in extracting information from dicom image databases for audit and research. **The British Journal of Radiology**, Oxford University Press, v. 96, n. 1151, p. 20230104, 2023.

MAGALHÃES, L. G. A. et al. Morte cerebral: Análise de achados na neuroimagem. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 9, n. 5, p. 1399–1408, 2023.

MAGALHÃES, T. A. et al. Diretriz de tomografia computadorizada e ressonância magnética cardiovascular da sociedade brasileira de cardiologia e do colégio brasileiro de radiologia–2024. **Arquivos Brasileiros de Cardiologia**, v. 121, n. 9, p. e20240608, 2024.

MARCHI, J. S. et al. **Anatomia do cérebro e ventrículos encefálicos: Modelos em 3D para cegos**. 2024.

MARIANELLI, M. Principais fatores de risco do avc isquêmico: Uma abordagem descritiva / main risk factors for ischemic stroke: A descriptive approach. **Brazilian Journal of Health Review**, v. 3, jun. 2020.

Medium. **Rede Neural Perceptron Multicamadas**. 2023. <<https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>>. Acessado em: 13-ago-2024.

MELO, H. M. et al. Associação das características clínicas da epilepsia do lobo temporal mesial resistente ao tratamento farmacológico com a disfunção do tônus autonômico cardíaco e a confiabilidade do registro de variabilidade da frequência cardíaca ultracurto. 2023.

- MERDAS, M. H. Elastic net – mlp – modelo baseado em smote (ems) para melhorar a previsão de AVC. **Medinformática**, v. 2, p. 73–78, 2024. Acesso em: 16 ago. 2024. Disponível em: <<https://ojs.bonviewpress.com/index.php/MEDIN/article/view/2470>>.
- MESQUITA, L. A. L.; OUTROS. **Computação Gráfica e Processamento de Imagens: Processamento Digital de Imagens**. Local de Publicação: Nome da Editora, 2023.
- MIRANDA-VIANA, M. et al. Dicom file format has better radiographic image quality than other file formats: an objective study. **Brazilian Dental Journal**, SciELO Brasil, v. 34, n. 4, p. 150–157, 2023.
- MONTANA, M.; JÚNIOR, P. Anatomia encefálica: Uma perspectiva a partir da análise de endocasts virtuais em mamíferos. In: **Ciência Animal e Veterinária: O Avanço da Ciência no Brasil**. [S.l.]: Editora Científica Digital, 2024. p. 35–52.
- MONTEIRO, A. C. et al. Tomografia computadorizada de perfusão cerebral no AVC isquêmico: previsão do aspecto final através dos valores de core e penumbra. **Saúde amp; Tecnologia**, n. 25, p. 25–37, Mai. 2021. Disponível em: <<https://journals.ipl.pt/stecnologia/article/view/480>>.
- MORAES, A. R. D. P. Estudo neuroanatômico do encéfalo em ovinos e dinâmica educacional imaginológica. Universidade Estadual Paulista (Unesp), 2024.
- MOURÃO, A. P. **Tomografia Computadorizada: Tecnologias e Aplicações**. 2. ed. [S.l.]: Editora Difusão, 2015.
- NASCIMENTO, C. V. da S. et al. A importância dos avanços das tecnologias em saúde como ferramentas de intervenções educativas relacionadas ao suporte para doenças crônicas: Uma revisão integrativa. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 9, n. 10, p. 242–250, 2023.
- NETO, M. G. A. et al. Abordagem de urgência no AVC: Diagnóstico rápido e intervenção eficaz para reduzir sequelas. **Brazilian Journal of Implantology and Health Sciences**, v. 6, n. 10, p. 2168–2177, 2024.
- NOGUEIRA, B. J. et al. Identificação de AVCs utilizando extração de características e uma rede MLP em imagens de TC. In: **Congresso da Sociedade Brasileira de Telecomunicações**. São Paulo, Brasil: [s.n.], 2023.
- OLIVEIRA, L. de; RUSTICK, A.; SANTOS, J. A. A. dos. Estimativa de vazão de um sistema de bombeamento fotovoltaico usando redes neurais artificiais. **RETEC-Revista de Tecnologias**, v. 16, n. 1, p. 62–72, 2023.
- OLIVEIRA, L. N. d. et al. A new natural detector (curcuma longa l.) for photodynamic therapy (pdt) measurements with blue led irradiations: Application of convolutional neural networks (CNN) and multilayer perceptron (MLP). ISIRYM, 2024.
- OLIVEIRA, M. S. de. **Análise de textura em imagens cerebrais: aplicações em acidente vascular cerebral isquêmico, epilepsia mioclônica juvenil, doença de Machado-Joseph, déficit cognitivo leve e doença de Alzheimer**. Tese (Tese de doutorado) — Universidade Estadual de Campinas, UNICAMP, 2010.

OLIVEIRA, V. S. et al. O uso da inteligência artificial no diagnóstico por imagens médicas baseadas no padrão dicom uma revisão sistemática. **Revista Multidisciplinar em Saúde**, v. 4, n. 3, p. 506–511, 2023.

PAIXÃO, G. M. de M. **Machine Learning na Medicina: Revisão e Aplicabilidade**. 2022. Sociedade Brasileira de Cardiologia. 8.

PAULSEN, F.; WASCHKE, J. **Sobotta: Atlas de Anatomia Humana**. 25^a. ed. Rio de Janeiro: Guanabara Koogan, 2023. ISBN 978-85-9515-953-2.

PESCININI, I. P.; VICTORINO, L. M.; COCLETE, G. E. G. S. Uso de tomografia computadorizada por feixe cônico no serviço de radiologia odontológica da foa-unesp: recurso no diagnóstico de fraturas do complexo bucomaxilofacial. **Revista da FOA-UNESP**, 2023.

PILAN, V. de P. **Técnicas de inteligência artificial para diagnóstico de Acidente Vascular Cerebral através de imagens e dados textuais sobre possíveis vítimas**. Dissertação (Dissertação (Mestrado)) — Universidade Estadual Paulista-FACULDADE DE CIÊNCIAS - CAMPUS BAURU, São Paulo, 2023.

PRADO, P. F. d. Estudo de descritores de texturas e cores para a classificação automática de imagens no contexto das ciências ambientais. Universidade Estadual Paulista (Unesp), 2018.

RODRIGUES, A. R. D. A. et al. Alterações anatômicas e funcionais do cérebro de pacientes com transtorno do déficit de atenção e hiperatividade. **Brazilian Journal of Implantology and Health Sciences**, v. 5, n. 4, p. 27–41, 2023.

RODRIGUES, F. d. A. A. et al. **Explorando os mistérios do sistema nervoso**. [S.l.]: Fabiano de Abreu, 2024.

ROSA, J. F. da C.; CLAUS, T. V.; PAULA, V. de. Manual prático de pós-processamento de imagens em tomografia computadorizada. **Disciplinarum Scientia| Naturais e Tecnológicas**, v. 25, n. 2, p. 207–224, 2024.

SAKURAI, R. **Implementando a estrutura de uma Rede Neural Convolutacional utilizando o MapReduce do Spark**. São Paulo-SP, 2023.

SALES, R. S. et al. Fatores associados a incapacidade funcional após acidente vascular cerebral isquêmico. **Acta Paulista de Enfermagem**, SciELO Brasil, v. 37, p. eAPE00601, 2023.

SANTOS, E. V. d. **Avaliação pré-clínica do efeito neuroprotetor do ácido rosmarínico em lesões de isquemia e reperfusão cerebral: correlações anátomo-funcionais**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, Brasil, 2020.

SANTOS, M. K. et al. Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. **Radiologia brasileira**, SciELO Brasil, v. 52, p. 387–396, 2019.

- SARMENTO, R. M. **Detecção e Classificação de Acidente Vascular Cerebral em Imagens de Tomografia Computadorizada por Extração de Características**. Dissertação (Mestrado) — Universidade Federal do Ceará, UFCE, 2021.
- SCORZA, F. A. et al. Neurogênese e pesticidas: a ausência de novos neurônios é a novidade. **Arquivos de Neuro-Psiquiatria**, v. 82, p. s00441786853, 2024.
- SILVA, A. M. C. D. et al. Anatomy alive: Aplicativo móvel para facilitar o ensino-aprendizagem de anatomia de cabeça e pescoço aplicada à odontologia. **Revista da ABENO**, v. 24, n. 1, p. 2201–2201, 2024.
- SILVA, B. K.; CARRO, S. A.; COSTA, M. G. Redes neurais aplicadas na investigação de avc por tomografia computadorizada. **Colloquium Exactarum**, p. 53–64, 2019. ISSN 2178-8332.
- SILVA, D. A. C. et al. A aplicação da tomografia computatdorizada no diagnóstico precoce de câncer de pulmão: Revisão sistemática. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 10, n. 6, p. 1985–1991, 2024.
- SILVA, E. T. A. et al. **Classificação do infarto de miocárdio a partir da extração de parâmetros de espaços de fase com o uso dos descritores de Haralick**. 2022. Mato Grosso. 25 de setembro, 2ª edição.
- SILVA, G. S.; MIRANDA, R. C. A. N.; MASAUD, R. M. **Acidente Vascular Cerebral: Prevenção, Tratamento Agudo e Reabilitação**. 2. ed. São Paulo, Brasil: Atheneu, 2015.
- SILVA, J.; ALMEIDA, M. Classificação e implicações clínicas da isquemia: uma revisão. **Revista Brasileira de Medicina**, v. 12, n. 2, p. 45–60, 2020.
- SILVA, J.; PEREIRA, M. Impacto das doenças neurológicas no sistema nervoso central e sua influência nas funções motoras e cognitivas. **Revista Brasileira de Neurologia e Neurociências**, v. 7, n. 2, p. 15–30, 2021.
- SILVA, V. d. O. et al. Uso de redes neurais para a predição de diagnóstico de ave: uma revisão sistemática. **Rev. Bras. Neurol.(Online)**, p. 21–28, 2022.
- SIMÃO, R. S. **Tomografia Computadorizada**. 1. ed. [S.l.]: Corpus, 2021.
- SOBEL, I. A 3x3 isotropic gradient operator for image processing. In: **Presented at the Stanford Artificial Intelligence Project (SAIL)**. Stanford, CA: [s.n.], 1968. p. 271–272.
- SOUZA, A. S. **Análise comparativa de redes neurais convolucionais para a detecção de câncer de pulmão em tomografias computadorizadas**. Dissertação (Master's thesis) — Universidade de Brasília, Instituto de Ciências Exatas, Departamento de Ciência da Computação, Brasília, 2023.
- SOUZA, V. S. S. Monografia (Graduação em Ciência da Computação), **Introdução à interpretabilidade de redes neurais convolucionais**. 2023.
- TAULLI, T. **Introdução à Inteligência Artificial: Uma abordagem não técnica**. [S.l.]: Novatec Editora, 2020.

TENGUAM, J. J. **Ensemble learning como estratégia para investigar imagens H&E utilizando duplo estágio de seleção de atributos**. Dissertação (Mestrado) — Universidade Estadual Paulista (Unesp), São Paulo, 2023.

YARIA, J. et al. Systematically addressing stroke burden in the developing world: A framework for effective implementation. In: **Ischemic Stroke Therapeutics: A Comprehensive Guide**. [S.l.]: Springer, 2024. p. 475–480.